

CORPORACIÓN MEXICANA DE INVESTIGACIÓN EN MATERIALES

DIVISIÓN DE ESTUDIOS DE POSGRADO



**AJUSTE DE PARÁMETROS Y AUTOMATIZACIÓN DEL PROCESO DE
TROQUELADO, CASO MAPISA**

POR

ING. SUSANA VIRIDIANA GUTIÉRREZ MARTÍNEZ

TESIS

MAESTRÍA EN INGENIERÍA INDUSTRIAL Y DE MANUFACTURA

SALTILLO, COAH. DICIEMBRE 2011

AJUSTE DE PARÁMETROS Y AUTOMATIZACIÓN DEL PROCESO DE TROQUELADO, CASO MAPISA

por

Ing. Susana Viridiana Gutiérrez Martínez

Tesis

Presentada al Programa Interinstitucional en Ciencia y Tecnología

Sede

Corporación Mexicana de Investigación en Materiales S.A. de C.V.

como requisito parcial para obtener el grado académico de

**Maestra en Ciencia y Tecnología
Especialidad en Ingeniería Industrial y Manufactura**

Programa Interinstitucional en Ciencia y Tecnología /Comimsa

Saltillo Coahuila, Diciembre 2011.

AJUSTE DE PARÁMETROS Y AUTOMATIZACIÓN DEL PROCESO DE TROQUELADO, CASO MAPISA

por

Ing. Susana Viridiana Gutiérrez Martínez

Comite Revisor

Tutor Académico: Dr. Giovanni Lizárraga Lizárraga
PICYT-Ing. Industrial y Manufactura-COMIMSA

Revisor No.1: Dr. Luis Martín Torres Treviño
Centro de Innovación, Investigación y Desarrollo en Ingeniería y Tecnología
(CIDIT-FIME)

Revisor No.2: Dr. José Alfredo Manzo Preciado
Centro de Ingeniería y Desarrollo Industrial.

Revisor No.3: Dr. Arnoldo Fernández
Instituto Tecnológico de Nuevo León.

Revisor No.4: Dr. Marco Aurelio Jiménez Gómez
PICYT-Ing. Industrial y Manufactura-COMIMSA

Tutor de planta: Ing. José Ervey Vázquez Luna
Ingeniero de manufactura / Maquinados y Pilotos Saldaña S.A. de C.V.

Saltillo Coahuila, Diciembre 2011.

DEDICATORIA

**A DIOS Y A MI MAMÁ:
LETICIA MARTÍNEZ ROMO**

Agradecimientos

A Dios por permitirme terminar esta etapa de mi vida y permitirme lograr mis sueños.

A mi familia Leticia Martínez Romo, Rosa Yadira Gutiérrez Martínez y Erick Cristhofer Gutiérrez Martínez por su apoyo incondicional.

A mi tutor, Dr. Giovanni Lizárraga Lizárraga por compartir sus conocimientos y principalmente por brindarme su amistad y su tiempo.

Al Dr. Marco Aurelio Jiménez Gómez por su apoyo para desarrollar el proyecto, por compartir sus conocimientos y experiencia, por brindarme su tiempo y su valiosa amistad.

A la empresa Maquinados y Pilotos Saldaña S.A de C.V especialmente al **Lic. Julio Saldaña** y a mi tutor de planta **Ing. José Ervey Vázquez Luna**, por apoyarme en cada paso de este proyecto y brindarme su confianza para trabajar en sus instalaciones. También agradezco a todas las personas que me ayudaron directa e indirectamente dentro de la empresa: personal administrativo, ingenieros de producción y mantenimiento y a los operadores que estuvieron en el área de troquelado.

Quiero agradecer a las personas que me ayudaron de alguna forma a culminar este trabajo: **al Dr. Mario Cantú Sifuentes, Dr. Felipe Garcia Vázquez, Dr. Pedro Pérez, al M.C. Juan Carlos Cisneros Torres, al Dr. David Salvador González González**, a cada uno gracias por su amistad y su ayuda incondicional cuando la necesité.

A mis Amigos: Dario, Evangelina, Luis Ángel, Jesús, Esmeralda, Flavio, Deniz, Abraham, Marisol, José Luis, Olga, Alfredo, Johana, Indira, Bernardo. Gracias a cada uno(a) por brindarme sus consejos y su valiosa amistad.

Al Consejo Nacional de Ciencia y Tecnología (CONACYT) por la beca otorgada para realizar mis estudios de posgrado y por el apoyo recibido mediante la convocatoria **Estímulos a la innovación** en la modalidad **INNOVAPYME 2010**.

“Autobiografía”

Susana Viridiana Gutiérrez Martínez, nació el 08 de abril de 1985 en la ciudad de Saltillo, Coahuila.

Del año 2004 al 2008, cursó sus estudios superiores en el Instituto Tecnológico de Saltillo obteniendo el título de Ingeniera en Mecatrónica.

Ha participado en el seminario de conformado y estampado por parte de la Corporación Mexicana de Investigación en Materiales S.A. de C.V. (COMIMSA), el Curso de Control Numérico Computacional de manufactura avanzada, ofrecido por el Instituto Tecnológico de Saltillo. También realizó la publicación en memoria de dos artículos de investigación y ha participado como expositor en el Congreso Internacional de Ingeniería Industrial y en el Congreso Mexicano de Inteligencia Artificial (COMIA 2011).

Sus áreas de investigación abordan las áreas de automatización de procesos, optimización de parámetros con herramientas de inteligencia artificial, análisis y simulación industrial.

Índice

1. Introducción	1
2. Planteamiento del problema	4
2.1. Descripción del problema	4
2.2. Preguntas de Investigación	5
2.3. Hipótesis	5
2.4. Objetivos	5
2.5. Justificación	6
2.6. Delimitaciones.	7
3. MARCO DE REFERENCIA	8
3.1. ESTADO DEL ARTE	8
3.1.1. Estampado de metales	8
3.1.2. Automatización	10
3.1.3. Optimización de parámetros	11
3.2. MARCO TEÓRICO	13
3.2.1. Estampado de metales	13
3.2.2. Diseño de Experimentos	18
3.2.2.1. Diseño de experimento factorial	19
3.2.2.2. Adecuación del Modelo en un Diseño de Experimentos	21
3.2.2.3. Prueba de significación	23

3.2.3. Redes Neuronales Artificiales	24
3.2.3.1. Reconocimiento de patrones	25
3.2.3.2. Aproximación de funciones	25
3.2.4. Modelo de las RNAs	26
3.2.4.1. Entrenamiento de las RNA	28
3.2.4.2. Algoritmo de retropropagación	29
3.2.4.3. Validación cruzada	30
3.2.4.4. Técnica de detención temprana	31
3.2.5. Computación Evolutiva	32
3.2.5.1. Programación Evolutiva	33
3.2.5.2. Estrategias Evolutivas	34
3.2.5.3. Algoritmos Genéticos	37
3.2.5.4. Ventajas de la computación evolutiva	38
4. METODOLOGÍA	39
4.1. Metodología propuesta	39
5. Resultados	42
5.1. Análisis del área	42
5.1.1. Proceso de troquelado.	43
5.1.2. Simulación del sistema	46
5.2. Automatización	48
5.3. Diseño Experimental.	52
5.4. Redes neuronales	56
5.5. Optimización a través de estrategias evolutivas	61
6. Conclusiones y trabajo futuro	63
6.1. Conclusiones	63
6.2. Trabajo futuro	64

<i>ÍNDICE</i>	III
Bibliografía	66
7. Anexos	70
7.1. Anexo I	70
7.2. Anexo II	72
7.3. Anexo III	83

Índice de Tablas

3.1. Análisis de varianza del modelo de tres factores.	22
5.1. Datos técnicos del alimentador electrónico.	48
5.2. Datos técnicos del porta-rollos tipo pallet.	49
5.3. Datos técnicos del lubricador.	51
5.4. Niveles utilizados para el DOE	53
5.5. Diseño de experimentos	54
5.6. Análisis de datos	56

Índice de Figuras

3.1. Esquema de los procesos de estampado.	14
3.2. Ejemplo de corte y troquelado	18
3.3. Ejemplo de una red neuronal artificial	26
3.4. Topología general de una neurona en una red neuronal artificial.	27
3.5. Arquitectura de una red de retropropagación	29
3.6. Curvas de detención temprana basada en la regla de validación cruzada. . .	32
3.7. Ejemplo de de codificación usada tradicionalmente en los algoritmos genéticos.	37
4.1. Esquema de pasos de la metodología	40
5.1. Soporte de uña.	42
5.2. Acomodar el rollo.	43
5.3. Alimentación de la prensa.	44
5.4. Rocío de refrigerante a la lámina.	45
5.5. Fin del proceso.	45
5.6. Simulación del proceso manual.	47
5.7. Actividades extra en el proceso de troquelado.	47
5.8. Alimentador y enderezador de lámina.	49
5.9. Porta-rollos tipo pallet	50
5.10. Aplicador de lubricante	50

5.11. Línea de producción automatizada	52
5.12. Gráfica de probabilidad normal de los residuales.	53
5.13. Gráfica de los residuales contra el tiempo.	55
5.14. Análisis de regresión para el entrenamiento de la RNA	58
5.15. Topología de la RNA final	60
7.1. Layout área de troquelado con sistema automatizado	71

Capítulo 1

Introducción

Este trabajo de tesis presenta el desarrollo de la automatización y optimización de parámetros en un proceso de conformado y estampado por medio de troqueles, el cual, permite el paso de un proceso manual a uno automatizado, con la ventaja de tener la optimización del proceso automatizado, teniendo como objetivo el incrementar en al menos un 20 % del tiempo útil de producción. El desarrollo del proyecto se realizó en el área de troquelado de la empresa denominada MAQUINADOS Y PILOTOS SALDAÑA S.A de C.V.(MAPISA), ubicados en la Calle No. 24 en la Colonia Vista Hermosa en la ciudad de Saltillo, Coahuila. En la que se obtiene como resultado el incremento de un 40 % en el tiempo útil de producción de la pieza denominada soporte de uña.

Actualmente, en la industria manufacturera tener procesos eficientes y eficaces es muy importante debido a que proporcionan estabilidad permitiendo la calidad en los productos, siendo uno de los principales retos dentro de la economía global, acelerado por la competencia de mercados y la demanda de mejores productos por parte de los clientes. Lo que obliga a empresas que tienen procesos manuales a modernizarse y automatizar sus líneas de producción.

Los problemas más frecuentes al querer automatizar un proceso son: la amplia investigación que se debe realizar para adquirir maquinaria nueva para un proceso determinado, el costo de personal especializado en cada sistema y el tiempo muerto que se produce en la inserción de la maquinaria en la línea de producción. Por lo cual, automatizar es un proceso lento pero necesario para las empresas. Finalmente la optimización del sistema automatizado generalmente no se lleva a cabo debido a la carga de trabajo que se le da a la línea automatizada, sin considerar el desgaste que se tiene en la maquinaria lo que genera pérdida de dinero en mantenimiento correctivo, el cual se puede evitar con la estabilización y optimización de los procesos.

En la presente investigación se propuso la automatización de la alimentación de un sistema de troquelado y el ajuste óptimo de parámetros por medio de técnicas de inteligencia artificial, permitiendo la reducción de tiempos muertos en la producción de piezas.

Este trabajo está estructurado en cinco capítulos, en el primero se desarrollan los puntos importantes de la investigación: la definición del problema, la justificación, la hipótesis, los objetivos y las limitaciones.

El segundo capítulo trata del marco de referencia, donde se identifica la situación actual de los procesos de manufactura, la automatización y la optimización de parámetros, permitiendo identificar algunos puntos claves de la investigación.

El tercer capítulo presenta la metodología utilizada para la automatización y optimización de la alimentación del proceso de troquelado.

El capítulo cuarto presenta el desarrollo de la experimentación y la obtención de resultados y validación. Se efectúa el análisis del área para su automatización, se desarrolla la implementación y finalmente la optimización de parámetros identificados.

Finalmente en el quinto capítulo se ofrece la discusión de resultados, las conclusiones del trabajo y se proponen investigaciones futuras. Con la idea de que esta investigación ayude a la industria manufacturera del país.

Capítulo 2

Planteamiento del problema

En este capítulo se describe de forma detallada el entorno del problema, el alcance, los objetivos, las hipótesis y la justificación del proyecto.

2.1. Descripción del problema

Actualmente, la industria manufacturera necesita sistemas automatizados para satisfacer las necesidades de producción solicitada por sus clientes sin perder la calidad del producto final y generando sistemas eficientes y eficaces.

En la industria manufacturera del país todavía se puede observar que las prensas se alimentan artesanalmente de lámina, generando pérdidas de tiempo y desperdicio de material, considerando que la operación depende completamente del colaborador volviendo vulnerable la producción, teniendo pérdidas monetarias para la empresa, evitando elevar su competitividad en el mercado nacional.

Debido a lo anterior, es importante no solo automatizar el sistema sino que éste se vuelva eficiente para satisfacer las necesidades de la producción que tiene la empresa y que lo largo del tiempo no incremente el desperdicio de material y tampoco perjudique la producción.

2.2. Preguntas de Investigación

- ¿Qué influencia tiene la alimentación del troquel en la generación de piezas con defectos?
- ¿Qué tanto se puede reducir el tiempo de operación actual?
- ¿De qué manera beneficiará al proceso de troquelado la automatización?
- ¿La correlación de parámetros se ajusta a una regresión lineal?
- ¿Qué técnica de inteligencia artificial utilizar en caso de que la correlación de parámetros no se ajuste linealmente?

2.3. Hipótesis

- Por medio de la automatización y un ajuste óptimo de parámetros en el sistema de troquelado, se incrementará el tiempo y la capacidad de producción.

2.4. Objetivos

OBJETIVO GENERAL

Automatizar y optimizar la línea de producción de troquelado para tener un incremento en el tiempo útil de producción de al menos un 20 %.

OBJETIVOS ESPECÍFICOS

- Identificar los puntos críticos de automatización del sistema de troquelado, a partir de la inspección del área.
- Generar acciones de automatización del sistema de troquelado.
- Realizar un análisis del área automatizada para identificar los parámetros que influyen para la optimización del sistema de troquelado.
- Realizar un análisis de correlación entre los parámetros del sistema automatizado.
- Realizar la optimización de los parámetros y su validación en la línea de producción.

2.5. Justificación

En una economía globalizada es determinante establecer políticas de estado que propicien y estimulen el crecimiento de la productividad nacional, tal como las existentes en el plan nacional de desarrollo 2007-2012, que repercuten en el incremento de la competitividad de nuestro país. En el contexto nacional, considerando los parámetros de competitividad por entidad federativa establecidos por el instituto mexicano de competitividad (IMCO) y datos del INEGI en materia de PIB industrial, empleo, educación, salud y vivienda; Coahuila, se encuentra posicionada entre los estados más industrializados del país, destacando una fuerte participación económica industrial donde el sector manufacturero ocupa el primer lugar con un 54.7%, seguido por la construcción con un 41.7% y en menor grado los sectores de comercio y servicios según el sistema de información empresarial mexicano (SIEM 2008).

El sector manufacturero está predominantemente orientado al sector automotriz cuyos principales eslabones de la cadena productiva son de ensamble y soldadura en la producción de carrocerías, motores, sistemas de transmisión, suspensiones, frenos y accesorios,

cuyas estrategias de competitividad requieren de flexibilidad y cambios rápidos de diseño de partes, por lo que es fundamental contar con tecnologías avanzadas que permitan un estricto control de calidad de sus productos. Lo que representa un nicho de mercado para las MIPYMES metal-mecánicas involucradas en la fabricación de componentes y subensambles de componentes para gas como es el caso de MAPISA.

Esta investigación tiene la finalidad de desarrollar un modelo de producción ad-hoc a las necesidades de la empresa que incluya la determinación de los mejores parámetros de producción a través del uso de técnicas estadísticas y simulación para el control de producción.

2.6. Delimitaciones.

El alcance de este proyecto está delimitado a la automatización y optimización en una línea de producción enfocada al producto de mayor demanda de la empresa MAPISA.

Capítulo 3

MARCO DE REFERENCIA

Dentro de este apartado se describe brevemente el estado del arte y algunos conceptos importantes para el desarrollo del trabajo tales como: los sistemas de estampado, la automatización y la optimización de parámetros por medio de inteligencia artificial.

3.1. ESTADO DEL ARTE

Se presentan a continuación los aspectos importantes de la literatura revisada, para determinar los conocimientos y aplicaciones actuales del tema de investigación, por lo tanto, se han analizado distintas aplicaciones usadas para la mejora de los sistemas de estampado y el uso de inteligencia artificial para la optimización de parámetros. En el transcurso de este capítulo, se podrá observar que actualmente no se ha realizado un estudio específico para la alimentación automatizada a la prensa.

3.1.1. Estampado de metales

Durante los últimos años la investigación del proceso de estampado ha buscado la mejor forma de integración de los sistemas y nuevas formas innovadoras de mejorarlo con el fin de obtener una mejor calidad en las piezas y que se tenga el menor desperdicio de material.

Una de éstas formas es la búsqueda de la optimización del material como lo desarrolló Dequan et al. [1] en el que por medio del uso de algunas tecnologías como: la viabilidad del proceso de estampado, el algoritmo óptimo para el diseño de la lámina, el diseño de la tira inteligente y el cálculo de fuerza, para que por medio de un sistema de diseño asistido por computadora (CAD, por sus siglas en inglés), se optimice la tira de lámina y se produzca un menor desperdicio de material en el proceso.

En la investigación realizada por Fadón et al. [2], se muestra el proceso de diseño de un troquel basado en la animación por medio del modelado sólido (Autodesk Inventor), en el cual se diseñaron las piezas que componen el ensamblaje y posteriormente se realizó una simulación lo que les permitió obtener una animación del funcionamiento del troquel; el cual permite una visualización del proyecto diseñado y que ayuda a la detección de posibles fallas en el diseño del troquel o de los elementos que lo conforman, a la vez que permite analizar mejoras en el diseño.

Analizando las necesidades que se tienen dentro de los troqueles progresivos en la industria R.D. Jiang, B.T. Lauw y A.Y.C. Nee [3], realizaron el diseño de un troquel progresivo, por medio de la representación de cada uno de sus componentes, utilizando un método de diseño CAD, buscando la reducción de la complejidad, del costo y la durabilidad del troquel. Se resalta como un importante resultado la reducción significativa en el tiempo empleado para el diseño de los troqueles progresivos.

Serdar Tumkor y Kishore Pochiraju [4] desarrollan el diseño de una matriz para troqueles progresivos en el que utilizaron un algoritmo genético con el fin de minimizar la diferencia entre el juego que se tiene en los dados obteniendo el balanceo de estos. Los autores mencionan que de esta forma se puede incrementar la vida de los dados, reducir el costo de mantenimiento para los componentes más usados y la seguridad operacional. Un

logro importante de los autores es ilustrar la aplicación y uso de los algoritmos genéticos para el diseño óptimo de troqueles progresivos.

Considerando que el estampado de metal en blanco depende de la habilidad del operador A.Y.C. Nee y V.C. Venkatesha [5], desarrollan un algoritmo heurístico para optimizar el material, teniendo en cuenta factores como el mínimo desperdicio de material, corrección de la anchura de la lámina y su orientación, proporcionando información sobre la alineación y precisión del centro de la prensa. Comparando la solución generada por computadora con las prácticas industriales de prueba y error.

Yanagida y Azushima [6] desarrollan un estudio para medir el coeficiente de fricción en estampado en caliente. Utilizando una simulación numérica mediante el método de elementos finitos, utilizando un simulador desarrollado por los autores. Los experimentos iniciales se llevaron a cabo en acero SPHC Y 22MnB5 en condiciones secas y posteriormente fueron evaluados en condiciones de lubricación. Los coeficientes de fricción obtenidos en condiciones lubricadas para los aceros fueron inferiores a los de condiciones secas. Los autores mencionan que se puede entender que el uso de lubricantes es eficaz para disminuir la carga y el desgaste de la matriz en el estampado.

3.1.2. Automatización

La automatización en la actualidad ha sido de gran auge para el crecimiento de la industria manufacturera, por lo que se busca que los procesos que dependen completamente del ser humano, sean reforzados con maquinaria que ayude a la calidad y rapidez del producto.

Pensando en la disponibilidad operativa de máquinas herramientas en la industria manufacturera Verl et al. [7], desarrollaron un algoritmo de monitoreo para máquinas por

medio de la ubicación de sensores. Se tomaron en cuenta como parámetros las unidades de posición disponibles en la máquina, tales como: la posición, la velocidad y el motor de corriente continua. El algoritmo compara los parámetros actuales con los que se tenían cuando el equipo estaba nuevo. Se logro cuantificar el desgaste en la máquina e incluso localizar y detectar fallas en partes específicas.

Giuseppina Ambrogio et al. [8], presentan una investigación sobre el incremento de la velocidad en maquinas herramientas, desarrollando una serie de experimentos por medio del análisis de varianza (ANNOVA) con el fin de verificar el desgaste que se tiene en la hoja de lámina. Teniendo como principales resultados los siguientes:

1. La rugosidad de la superficie de la pieza está fuertemente influenciada por el paso de la profundidad de la herramienta.
2. Con respecto a la precisión de la pieza, el avance de herramienta puede ser aumentada hasta dos veces la magnitud sin una reducción en la geometría de la pieza

Los autores mencionan que el uso de un sistema de refrigerante adecuado y una máquina de alto rendimiento pueden permitir la formación gradual de piezas para convertirse en una alternativa en procesos tecnológicos.

3.1.3. Optimización de parámetros

La optimización de parámetros ha sido utilizada recientemente en la industria con el fin de tener tecnología de alto nivel, procurando tener un menor desperdicio en los procesos de producción y maquinaria eficiente. Uno de los métodos utilizados actualmente para la optimización de parámetros es el de inteligencia artificial, en esta sección se muestran algunos resultados del uso de estos métodos en la actualidad.

En el estudio para la optimización de parámetros en diferentes áreas se encontró la investigación de Jorge Hurtado [9] la cual se denomina “Optimización basada en confiabilidad por medio de redes neuronales y algoritmos evolutivos”, la cual estudia los parámetros en el diseño de estructuras complejas utilizando estructuras metálicas, con el fin de simplificar el trabajo se utilizan redes neuronales artificiales (RNA) para representar el comportamiento del sistema, para posteriormente combinarlo con algoritmos evolutivos(AE) como método de optimización global de las funciones considerando condiciones de probabilidad.

Para el estudio de desgaste en máquinas Marek Balazinski [10], utiliza tres métodos de inteligencia artificial para estimar el desgaste de la herramienta en un torno, realizando una comparación entre los métodos llamados “convencionales” (redes neuronales y lógica difusa) con la propuesta del autor. Esta propuesta consiste en usar una combinación de red neuronal artificial de retro-propagación y el método de lógica difusa para determinar el desgaste de la herramienta por medio de la fuerza de corte. El autor obtiene como resultado que los tres métodos proporcionan valores de desgaste similares y aceptables, mencionando que diferencia entre los metodos es: que para el sistema de lógica difusa es necesaria la habilidad del operador y para el de redes neuronales no es necesaria la habilidad del operador, pero el tiempo es semejante al sistema nuevo, el cual tiene como ventaja el que puede ser optimizado fácilmente y ejecutado con mayor facilidad por el operador.

En su trabajo Sun Jin et al. [11], desarrollan un método para el diseño automático de la secuencia de ensamble y su optimización. Para la comprobación de este método se ilustra el montaje de automóviles para el que se resume en cuatro pasos fundamentales: el modelo de conjuntos, la planificación de la secuencia, la optimización de la localización del programa de trabajo, la evaluación de la calidad dimensional y la optimización por medio

de algoritmos genéticos (AG). Los autores mencionan que el método puede ser aplicado a sistemas mecánicos complejos, tales como carrocerías, el cuerpo de una locomotora, el casco de un buque entre otros.

3.2. MARCO TEÓRICO

3.2.1. Estampado de metales

El estampado de metales es actualmente uno de los principales procesos de fabricación en la industria automotriz, espacial, aparatos electrodomésticos, en la producción de escritorios, carrocerías, fuselajes de aviones entre otros productos. Para el estampado de metales se tienen una serie de pasos hasta llegar al producto final. En la Figura 3.1, se muestra el proceso de transformación de lámina por medio del estampado utilizando prensas, el cual está dividido en una serie de pasos que permiten obtener productos de forma específica, este proceso inicia con la lámina ya sea en rollo o placa, para posteriormente realizar diferentes operaciones por ejemplo: el ranurado, corte, serrado o enderezado, después se procede al formado de la pieza mediante troqueles (punzones, dados) los cuales pueden ser: compuestos, progresivos o de transferencia. En la operación de troquelado se pueden realizar las siguientes operaciones: punzonado, corte de piezas, estampado, doblado, formado de rodillos, embutido, entre otros. Finalmente se procede a la limpieza de la pieza y la pintura en caso de ser necesario. Debido a la complejidad del proceso de troquelado se requiere un estricto control en cada uno de sus pasos [12].

A continuación se describen de forma detallada cada una de las características de los procesos para el formado de lámina.

Formado por laminación. Piezas largas con perfiles transversales complicados; buen acabado superficial; grandes tasas de producción; altos costos de herramientas.

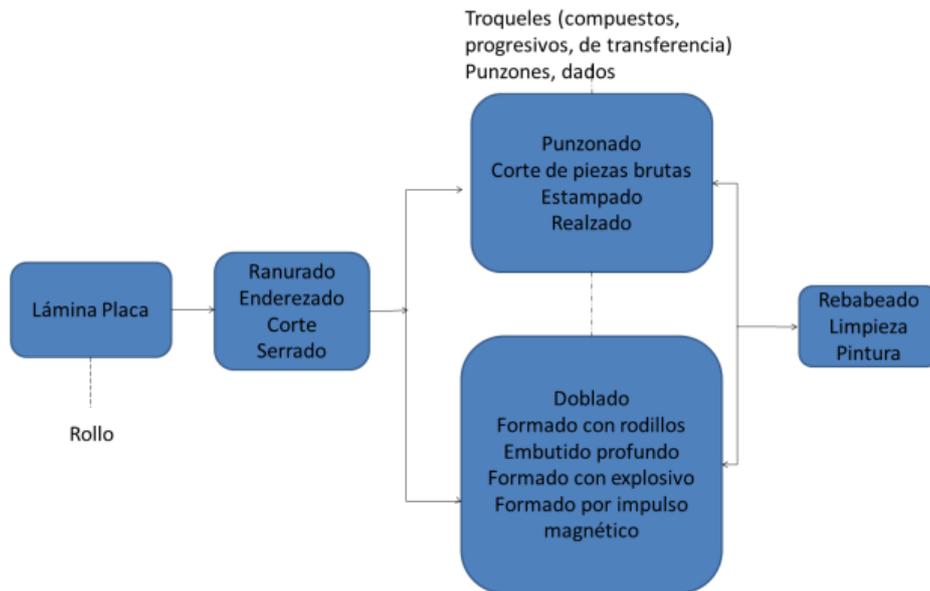


Figura 3.1: Esquema de los procesos de estampado.

Formado por extensión. Piezas grandes con contorno superficial; adecuado para pequeñas producciones; altos costos de mano de obra; los costos de herramientas por equipo dependen del tamaño de la pieza.

Embutido. Piezas superficiales o profundas con formas relativamente simples; grandes producciones; altos costos de herramientas y equipo.

Estampado. Incluye una diversidad de operaciones, como punzonado, recorte de piezas en blanco, realzado, doblado y acuñado; formas simples o complicadas con grandes producciones; los costos de herramientas y equipo pueden ser altos, pero los costos de mano de obra son bajos.

Formado con hule. Embutido y realzado de formas simples o complicadas; la superficie de la lámina se protege con membranas de hule; flexibilidad de operación; bajos costo de herramientas.

Rechazado. Piezas grandes o pequeñas, con simetría axial; buen acabado superficial; bajos costos de herramienta, pero los costos de mano de obra pueden ser altos, a menos que se automaticen las operaciones.

Formado super-plástico. Formas complicadas, gran detalle y tolerancias estrechas; los tiempos de formación son largos y por ello la rapidez de producción es baja. Piezas no adecuadas para uso en alta temperatura.

Repujado. Contornos superficiales, en laminas grandes; flexibilidad de operación; los costos de equipo pueden ser altos; el proceso también se usa para enderezar piezas.

Formado por explosión. Láminas muy grandes con formas relativamente complicadas, aunque por lo general con simetría axial bajos costos de herramientas, pero altos costos de mano de obra; adecuado para pequeñas producciones; grandes tiempos de ciclo.

Formado por impulso magnético. Operaciones de formado superficial abombado y realizado con láminas de resistencia relativamente baja; muy adecuado para formas tubulares; grandes tasas de producción; requiere herramientas especiales.

Existen algunas características importantes de los metales en la conformación de lámina los cuales son los siguientes:

- **Elongación.** Determina la capacidad del metal laminado para estirarse sin estrangularse ni fallar.
- **Porcentaje de elongación en punto de fluencia.** Se observa con láminas de acero suave; también se llaman bandas de Lüder y deformaciones de extensor; causa depreciaciones en forma de llamas en la superficies de la lámina, puede eliminarse por laminado de temple, pero debe formar la lámina antes que pase cierto tiempo después de laminar.

- Anisotropía (planar). Muestra un comportamiento distinto en distintas direcciones en el plano; presente en las hojas laminadas en frío por la orientación preferencial o hilo metálico.
- Anisotropía (normal). Determina la forma de adelgazamiento de los metales laminados durante el estirado; es importante en operaciones de embutido profundo.
- Tamaño de grano. Se determina la aspereza superficial en la lámina metálica estirada, cuando mayor es el grano la apariencia es más áspera; también afecta la resistencia del material.
- Esfuerzos residuales. Causados por deformación no uniforme durante el formado; causa distorsión de parte cuando se corta ésta, y puede originar corrosión bajo tensiones, se reduce o elimina con relevado de esfuerzos.
- Restitución. Debida a la recuperación elástica de la hoja deformada elásticamente después de quitar la carga, causa distorsión de la pieza y pérdida de exactitud dimensional; se puede controlar con técnicas como sobre doblado y recargado del punzón.
- Plegado. Debido a esfuerzos de compresión en el plano de la lámina; puede ser indeseable o útil, para impartir rigidez a las piezas, se puede controlar con el diseño adecuado de herramientas y dados.
- Calidad de orillas cortadas. Depende del proceso usado, las orillas pueden ser ásperas, no estar a escuadra y contener grietas. Los esfuerzos residuales y una capa endurecida por trabajo, todo ello es perjudicial para la capacidad de formado de la lámina, se puede mejorar la calidad controlando holguras, diseño de herramienta y punzón, afilado de la lámina en blanco, rasurado y lubricación.

- Condición superficial de la lámina. Depende de la práctica del laminado, es importante en el formando de la lámina porque puede causar desgarramiento y mala calidad de la superficie.

El trabajo de la prensa se realiza siempre en frío, es decir, a temperatura ambiente. Y se clasifica en dos grandes grupos de operaciones, el estampado y el forjado en frío. En el estampado se aplica una fuerza o presión constante para formar el material mientras que el forjado en frío se asemeja más al forjado de herrería donde se forma el material por compresión o con repetidos golpes. En el estampado el material se trabaja en forma de placas o laminado en hojas de diferentes espesores; en el forjado en forma de rebanadas o cilindros.

Corte y troquelado. Las operaciones de este tipo se caracterizan por el fenómeno de corte en su amplio sentido. Se les llama corte a aquellos procesos que cortan el material y lo separan. La línea que separa las piezas se conoce como línea de corte. El concepto de corte en su amplio sentido se divide en corte y el troquelado. La condición para que el proceso se llame corte en su sentido restringido es que la línea de corte sea abierta. Para el troquelado la condición es una línea de corte cerrada en la Figura 3.2 se muestra un ejemplo de cada una de estas operaciones.

Actualmente, existen dos tipos de corte el: corte de silueta o blanking, el cual es, cuando la silueta troquelada es el material a trabajar y el de punzonado o perscing, que consiste en que el material es punzonado pero se trabajara posteriormente. Un concepto importante es de desecho o scrap, es el nombre que se le da al material sobrante de la lámina y finalmente es importante la lubricación para reducir el desgaste de herramientas y dados, así como para mejorar la calidad de los bordes.

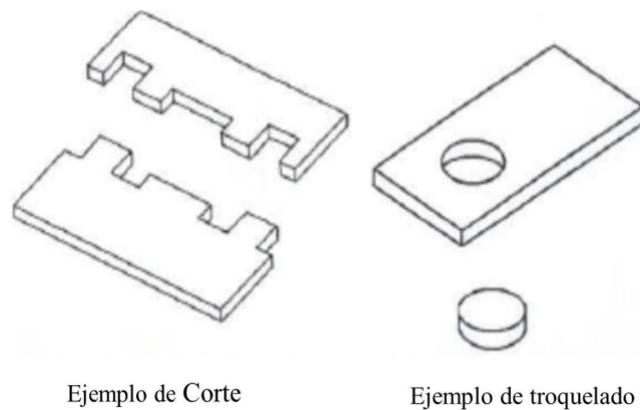


Figura 3.2: Ejemplo de corte y troquelado

3.2.2. Diseño de Experimentos

Gran parte de la investigación en la ingeniería, las ciencias y la industria, es empírica y hace uso extensivo de la experimentación. Los métodos estadísticos pueden incrementar, en gran medida, la eficiencia de estos experimentos y, con frecuencia, pueden fortalecer las conclusiones obtenidas. El uso correcto de las técnicas estadísticas en la experimentación requiere que el experimentador tenga presente los puntos siguientes: [13]

1. Uso de conocimientos no estadísticos del problema. Se refiere al conocimiento sobre el proceso bajo análisis, los factores que lo afectan, análisis e interpretación de resultados, entre otros.
2. Mantener el diseño y el análisis tan simple como sea posible, es necesario no exagerar en el uso de técnicas estadísticas complejas, si un diseño se hace de manera cuidadosa y correcta, el análisis casi siempre será relativamente directo.
3. Los experimentos son generalmente iterativos, es decir los niveles de los factores de las variables bajo análisis tienden a cambiar entre una iteración y otra.

Existe una gran variedad de tipos de experimentos, la selección del método adecuado dependerá de la aplicación bajo análisis, pero de manera general, el experimento busca determinar los factores o tratamientos que afectan la variable de respuesta del proceso, los niveles de estos tratamientos se cambian para verificar la afectación y se realiza una combinación de tratamientos y niveles, para finalmente, observar la respuesta y realizar el análisis.

A cada observación de un experimento se le llama corrida, a las variaciones en los resultados de las corridas individuales se le conoce como ruido o error experimental. Las variables de respuesta de un experimento son variables aleatorias, pudiendo ser continuas o discretas.

3.2.2.1. Diseño de experimento factorial

En muchos experimentos intervienen el estudio de los efectos de dos o más factores, el tipo de diseño factorial puede definirse como el más apropiado para esta aplicación [13].

Por diseño factorial se entiende que en cada ensayo o réplica completa del experimento se investigan todas las combinaciones posibles de los niveles de los factores. El efecto de un factor se define como el cambio de respuesta producido por un cambio en el nivel del factor, con frecuencia se le llama el efecto principal y puede visualizarse como la diferencia entre la respuesta promedio con un nivel bajo del factor y la respuesta promedio con el nivel alto del factor. Los diseños factoriales ofrecen varias ventajas, son más eficientes que los de un factor a la vez, y es muy útil cuando existen interacciones entre los factores del experimento, permiten también la estimación de los efectos de un factor con varios niveles de los factores restantes.

Considérese el caso de un experimento en el que existen a niveles del factor A , b niveles del factor B , c niveles del factor C , etc., dispuestos en un experimento factorial. En general habrá $abc\dots n$ observaciones totales si se hacen n réplicas del experimento completo. Cuando todos los factores del experimento son fijos, es sencillo formular y probar hipótesis acerca de los efectos principales y las interacciones, los estadísticos de prueba para cada efecto principal e interacción pueden construirse dividiendo el cuadrado medio, cuya fórmula se presenta a continuación:

$$MS_{Tratamientos} = \frac{SS_{Tratamientos}}{a - 1} \quad (3.1)$$

Con el cuadrado medio del error, cuya fórmula es:

$$MS_E = \frac{SS_E}{N - a} \quad (3.2)$$

Todas estas serán pruebas con el estadístico F . El número de grados de libertad de cualquier factor principal es el número de niveles del factor menos uno, y el de las interacciones es el producto del número de grados de libertad asociados de los componentes individuales. El número de grados de libertad de una suma de cuadrados es igual al número de elementos independientes en dicha suma.

A manera de ejemplo, se muestra en la Tabla 3.1 el análisis de varianza para un experimento de tres factores, los resultados de esta tabla permiten determinar el efecto de los factores y sus interacciones en el proceso bajo análisis.

Para el caso general de un diseño factorial de k factores con dos niveles cada uno, incluirá k efectos principales, $k/2$ interacciones de dos factores, $k/3$ intersecciones de tres factores, y así sucesivamente y una interacción de k factores, es decir, para un diseño de k factores en dos niveles el modelo completo tendría 2^{k-1} efectos. El primer paso para el análisis es estimar los efectos de los factores y examinar sus signos y magnitudes, de este modo el experimentador obtiene información preliminar espectro de los factores y las interacciones pueden ser importantes, y en que direcciones deberán ajustarse esos factores para mejorar la respuesta [13].

Para formar el modelo inicial del experimento, por lo general se elige el modelo completo con todos los efectos principales y las interacciones, siempre que haya realizado una réplica de al menos uno de los puntos del diseño, después se realiza un análisis de varianza para probar, que tan significativos son los efectos principales y las interacciones. Es recomendable una vez que se obtiene el análisis retirar del modelo aquellos factores que no sean significativos dentro del modelo y volver a realizar el análisis para obtener un modelo adecuado.

3.2.2.2. Adecuación del Modelo en un Diseño de Experimentos

La descomposición de la variabilidad presente en las observaciones, mediante la identidad del análisis de varianza, genera una relación algebraica. Para probar formalmente que hay diferencias en las medias de los tratamientos se requiere que se satisfagan algunos supuestos.

Debe existir un modelo que describa de manera adecuada las observaciones, los errores deben seguir una distribución normal e independiente con media cero y varianza σ^2 constante pero desconocida. Si estos supuestos se satisfacen, el procedimiento del análisis de varianza es una prueba exacta de la hipótesis de que no hay diferencia en las medias

Tabla 3.1: Análisis de varianza del modelo de tres factores. Tomado de [13]

Fuente de variación	Suma de cuadrados	Grados de libertad	Cuadrado medio	Cuadrado medio esperado	F_0
A	SS_A	$a - 1$	MS_A	$\sigma^2 + \frac{bcn}{a-1} \sum \tau_i^2$	$F_0 = \frac{MS_A}{MS_E}$
B	SS_B	$b - 1$	MS_B	$\sigma^2 + \frac{acn}{b-1} \sum \beta_j^2$	$F_0 = \frac{MS_B}{MS_E}$
C	SS_C	$c - 1$	MS_C	$\sigma^2 + \frac{abn}{c-1} \sum \gamma_k^2$	$F_0 = \frac{MS_C}{MS_E}$
AB	SS_{AB}	$(a-1)(b-1)$	MS_{AB}	$\sigma^2 + \frac{cn}{(a-1)(b-1)} \sum (\tau\beta)_k^2$	$F_0 = \frac{MS_{AB}}{MS_E}$
AC	SS_{AC}	$(a-1)(c-1)$	MS_{AC}	$\sigma^2 + \frac{bn}{(a-1)(c-1)} \sum (\tau\gamma)_k^2$	$F_0 = \frac{MS_{AC}}{MS_E}$
BC	SS_{BC}	$(b-1)(c-1)$	MS_{BC}	$\sigma^2 + \frac{an}{(b-1)(c-1)} \sum (\beta\gamma)_k^2$	$F_0 = \frac{MS_{BC}}{MS_E}$
ABC	SS_{ABC}	$(a-1)(b-1)(c-1)$	MS_{ABC}	$\sigma^2 + \frac{n}{(a-1)(b-1)(c-1)} \sum (\tau\beta\gamma)_k^2$	$F_0 = \frac{MS_{ABC}}{MS_E}$
Error	SS_E	$abc(n-1)$	MS_E	σ^2	
Total	SS_T	$abcn - 1$			

de los tratamientos.

Las violaciones de los supuestos básicos y la adecuación del modelo puede investigarse con facilidad mediante el examen de **residuales**. El examen de residuales deberá ser una parte automática de cualquier análisis de varianza. La verificación del supuesto de normalidad en los residuales puede hacerse construyendo una gráfica de probabilidad normal de los residuales, la cual traza los residuos para cada observación contra el valor esperado de ese residuo proveniente de una distribución normal. La gráfica de los residuales, en el orden temporal de la recolección de datos, es útil para detectar correlaciones entre los residuales, si no se ha violado ningún supuesto y no hay fuentes de variación “sobrantes” distintas al error experimental, este diagrama debe mostrar una *dispersión aleatoria*, es decir, no se debe tener una tendencia en el comportamiento de los residuales [14].

3.2.2.3. Prueba de significación

La prueba de significación es un procedimiento para determinar si existe una relación lineal entre la variable de respuesta y y un subconjunto de regresores x_1, x_2, \dots, x_k . El procedimiento de prueba incluye un análisis de varianza en el que se hace la partición de la suma de cuadrados total SS_T a la suma de cuadrados debida al modelo y una suma de cuadrados debida a los residuales es decir:

$$SS_T = SS_R + SS_e \quad (3.3)$$

De manera alternativa, se usa el valor P , para la prueba de hipótesis y , por lo tanto, rechazar H_0 si el valor P del estadístico F_0 es menor que α [13].

3.2.3. Redes Neuronales Artificiales

Las redes neuronales artificiales son una rama de la inteligencia artificial. La cual busca hacer ingeniería inversa del funcionamiento del cerebro humano. Teniendo como objetivo principal el reproducir el mecanismo humano de aprendizaje y el reconocimiento de patrones en forma de que una computadora lo pueda entender. [15]

Actualmente las redes neuronales son usadas en varias áreas de la ciencia como matemáticas, ingeniería, medicina, finanzas, la literatura, entre otros. A continuación se mencionan algunos ejemplos del uso de las redes neuronales para diferentes aplicaciones:

Aeroespacial Aviones de alto rendimiento, sistemas de control de aviones, mejoras de piloto automático, aviones detectores de fallas en componentes.

Automotriz Sistemas automáticos de orientación, para analizadores de garantía.

Militar Dirección de armas, seguimiento de objetivos, discriminación de objetos, reconocimiento facial, nuevos tipos de sensores, sonar, radar y señal de la imagen, procesamiento de compresión de datos, extracción de características y supresión de ruido, relación señal/identificación de la imagen.

Financiero Evaluación de bienes raíces, asesor de crédito, detección de hipotecas, en las empresas para la calificación de los bonos, el análisis del uso de la línea de crédito, análisis financieros de las empresas, la predicción de los precios de la moneda.

Manufactura Manufactura del control de procesos, diseño y análisis de productos, proceso y el diagnóstico de la máquina, identificación en tiempo real de las partículas, sistemas visuales de inspección de calidad, análisis de la calidad de la soldadura, la predicción de la calidad del papel, la calidad de chips para computadoras, productos químicos, el análisis de mantenimiento de maquinaria.

Medicina Análisis de las células cancerígenas, diseño de prótesis, la optimización de los tiempos del trasplante, la reducción de los gastos del hospital, en el hospital: la mejora de la calidad, asesoramiento en la sala de emergencias.

Aunque estas no son las únicas aplicaciones de RNA se puede observar la gran cantidad de problemas en los cuales pueden intervenir debido a que logran resolver dos importantes problemas: el de la clasificación o reconocimiento de patrones y la aproximación de funciones.

3.2.3.1. Reconocimiento de patrones

Los seres humanos tienen la capacidad de encontrar patrones sin esfuerzo, pero las matemáticas necesitan del análisis y diseño de máquinas que realicen el reconocimiento. En la década de 1930, R. A Fisher estableció los principios matemáticos de reconocimiento estadístico de patrones, la cual es una de las formas más rigurosa para formular el problema.

Al tener diferentes datos se forma una distribución natural de puntos la cual lleva a la definición de las clases o regiones de la categoría en el espacio de patrones. El objetivo del reconocimiento de patrones es la construcción de máquinas, llamadas clasificadoras, que asignan automáticamente las mediciones a las clases. El problema central de reconocimiento de patrones es para definir la forma de colocación de los límites para que los errores de asignación de clases se reduzcan al mínimo [16].

3.2.3.2. Aproximación de funciones

Las redes neuronales artificiales son usadas para la aproximación de funciones, debido a que por medio de datos de entrada y de salida de la función original puede entrenarse la red para que aproxime a la función. Pudiendo enmarcar este problema como una aproximación de funciones, si se asume que la respuesta deseada es una función desconocida, pero se conocen varios puntos por donde pasa la función. Las redes neuronales artificiales son

útiles debido a que son aproximadores universales, son eficientes y se pueden implementar en máquinas de aprendizaje (computadoras) [16].

3.2.4. Modelo de las RNAs

Los estudios en RNA empezaron con el trabajo de McCulloch y Pitts [17] y fue seguido por Rosenblatt [18] , Widrow y Hoff [19] , Minsky y Papert [20] , y muchos otros. Un ejemplo de una RNA se puede ver en la Figura 3.3, donde podemos ver algunos de los elementos de una RNA.

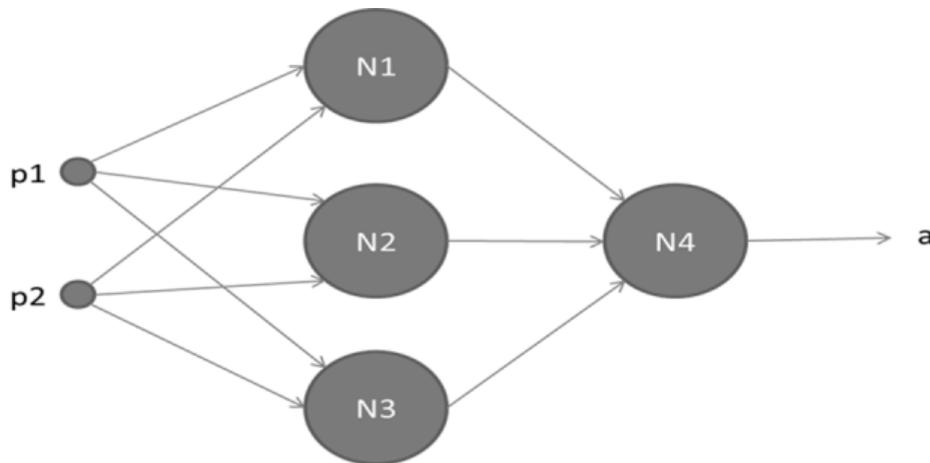


Figura 3.3: Ejemplo de una red neuronal artificial

En este ejemplo tenemos dos valores de entrada representada por $p1$ y $p2$, pero una RNA puede tener cualquier número finito de entradas. Las neuronas en esta red están representadas por los círculos $N1, N2, N3$ y $N4$. Las neuronas $N1, N2, N3$ forman la primera capa de la red. La primera capa recibe y procesa las entradas de la red, y transmite una salida a la segunda capa. La segunda capa consiste en $N4$. En este ejemplo, la segunda capa recibe los resultados de la primera capa y devuelve la salida de la red (a). Esta red representa una función que recibe dos valores ($p1$ y $p2$) y devuelve un valor (a), las RNA puede tener varias capas. La última capa se conoce como capa de salida y devuelve la

respuesta de la red a los patrones de entrada. Las capas entre la capa de salida y las entradas se llaman capas ocultas. Las capas ocultas hacen la mayor parte del trabajo cuando se aproxima una función. Cada capa de una RNA, incluyendo la capa de salida, puede tener un número arbitrario de neuronas. Cada neurona de una capa transmite una señal a cada neurona de la capa siguiente. Esta topología se inspira en la forma en que las neuronas están interconectadas en el cerebro. La topología general de una neurona en una RNA se muestra en la Figura 3.4.[21]

En esta figura se puede observar que una neurona recibe dos entradas p_1 y p_2 . Las

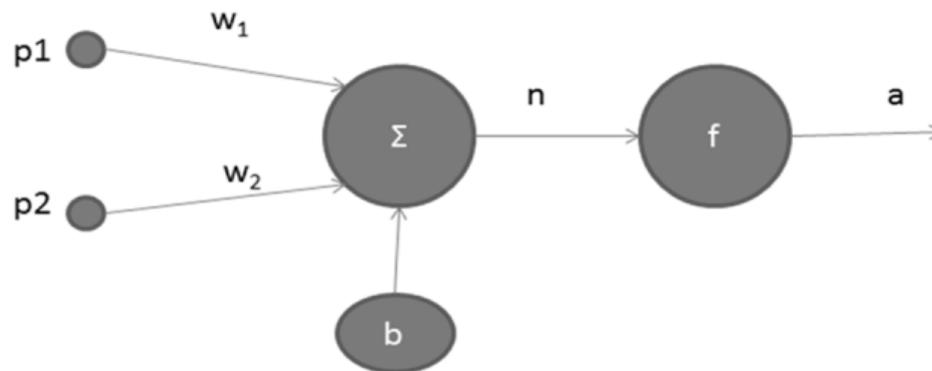


Figura 3.4: Topología general de una neurona en una red neuronal artificial.

entradas pueden ser los valores de entrada a la red, o las salidas de las capas anteriores. Cada entrada se multiplica por un peso W_{ij} , donde i es el número de la neurona que recibe la entrada y j es el número de la neurona que envía la señal. Estas multiplicaciones se suman junto con otro peso b , también llamado sesgo. El resultado de esta suma se llama n , el cual es modificado por una función f , la cual se conoce como función de transferencia. Finalmente, la evaluación de la función de transferencia es la salida “a” de la neurona.

Se ha demostrado que una RNA con dos capas de neuronas puede aproximar cualquier función en cualquier grado, siempre y cuando se tengan suficientes neuronas en la capa oculta. Para este fin, la capa oculta debe tener una función de transferencia monótona cre-

ciente y acotada, y la capa de salida debe utilizar una función de transferencia lineal[22]. Sin embargo, es necesario estimar el número de neuronas en la capa oculta. Los datos obtenidos de las muestras deben semejar a una función de cualquier grado por lo que es posible utilizar redes neuronales artificiales para estimar una población mayor de datos.

3.2.4.1. Entrenamiento de las RNA

Para realizar el entrenamiento de la RNA se utiliza un algoritmo, el cual busca ajustar los pesos y los sesgos de la red para aproximar la función deseada. Una ventaja de las RNAs es la facilidad de “aprender” los valores para los pesos siguiendo las reglas de aprendizaje. Existen tres tipos de entrenamiento: el entrenamiento supervisado, el entrenamiento no supervisado y el entrenamiento por refuerzo [21].

Entrenamiento supervisado En el entrenamiento supervisado, se cuenta con un conjunto de ejemplos de comportamiento de la red:

$$\{P_1, t_1\}, \{P_2, t_2\}, \dots \{P_Q, t_Q\} \quad (3.4)$$

donde p , es una entrada a la red y t , es la salida (objetivo). Como las entradas se aplican a la red, las salidas de la red se comparan con los objetivos. El entrenamiento se utiliza para ajustar los pesos y sesgos de la red con el fin de mover la red a las salidas correspondientes al objetivo.

Entrenamiento por refuerzo El entrenamiento por refuerzo es similar al entrenamiento supervisado, con la excepción de que, en lugar de contar con la salida correcta para cada entrada de la red, en el algoritmo sólo se le da un grado. El grado (o porcentaje) es una medida del rendimiento de la red más una secuencia de entradas. Este tipo de aprendizaje es mucho menos común que el aprendizaje supervisado.

Entrenamiento no supervisado. En el entrenamiento no supervisado, los pesos y los sesgos se han modificado en respuesta a las entradas de la red solamente. No hay

ningún objetivo de salidas disponibles. La mayoría de estos algoritmos realizan algún tipo de operación de agrupación, es decir, aprenden a clasificar los patrones de entrada en un número finito de clases.

3.2.4.2. Algoritmo de retropropagación

Es un algoritmo de entrenamiento multicapa consiste en propagar el error hacia atrás, es decir, de la capa de salida hacia la capa de entrada, pasando por las capas ocultas intermedias y ajustando los pesos de las conexiones con el fin de reducir dicho error, la Figura 3.5 muestra la arquitectura de este algoritmo.

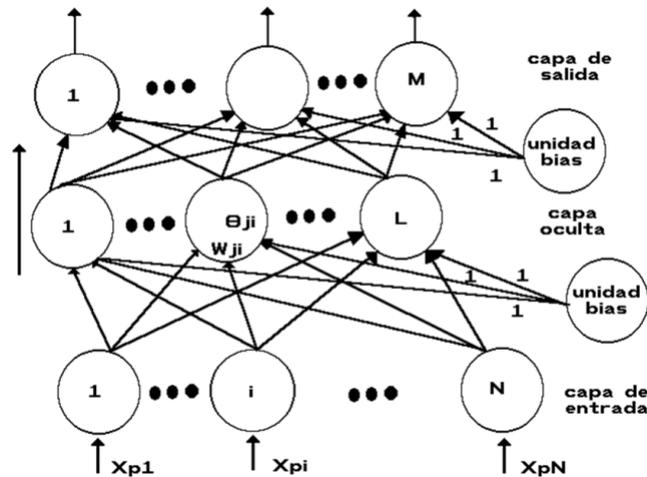


Figura 3.5: Arquitectura de una red de retropropagación[21].

Este algoritmo utiliza la regla delta en la capa oculta de la red, para calcular el incremento a aplicar a un peso como una proporción directa de la tasa de variación del error. Utiliza una metodología de aprendizaje del gradiente de descenso y finalmente resuelve el problema de asignación de porcentaje mediante el uso de valores de peso en la topología de la red. Para el uso de este algoritmo se tienen que empezar a calcular los errores locales desde la salida de la red hacia la entrada [16].

El algoritmo de retropropagación ha tenido algunas variantes debido a que en aplicaciones prácticas resulta demasiado lento, por lo que se ha investigado métodos para acelerar el algoritmo de convergencia. Los algoritmos más veloces se clasifican en dos categorías:

1. Técnicas Heurísticas

- Momento
- Razón de aprendizaje variable

2. Técnicas de optimización numérica

- Algoritmo de gradiente conjugado
- Algoritmo de Levenberg-Marquardt

3.2.4.3. Validación cruzada

En busca de tener una aproximación correcta en las RNAs se utiliza el aprendizaje de retro-propagación, en el que se tiene el problema de seleccionar la red dentro de un conjunto de estructuras modelo y elegir el “mejor” de acuerdo a un criterio determinado. En este contexto, una herramienta estadística conocida como validación cruzada es una buena opción, en primer lugar el conjunto de entrenamiento es dividido aleatoriamente en dos subconjuntos:

- Conjunto de entrenamiento, que se utiliza para seleccionar el modelo.
- Conjunto de validación, que se utiliza para probar o validar el modelo.

Con el fin de validar el modelo con un conjunto de datos diferente al que se utiliza para la estimación de parámetros, de esta manera, el conjunto de entrenamiento debe evaluar el desempeño de los modelos candidatos y elegir “el mejor”. Sin embargo, existe el

riesgo de sobre entrenamiento en el conjunto de validación, para evitar esta posibilidad, se selecciona un conjunto de prueba, el cual, es diferente al conjunto de validación.

Para obtener el modelo de validación se utilizan los resultados propuestos por Kearns en 1996, el cual propone utilizar el 80 % de los datos en el conjunto de entrenamiento al cual se le asigna un subconjunto de prueba y un 20 % restante al conjunto de validación.

La validación cruzada es una buena técnica para el diseño de RNAs, la cual se puede utilizar para determinar el número de neuronas en la capa oculta y cuando se tenga que dejar de entrenar la red, mejor conocida como técnica de detención temprana (early stopping) [24].

3.2.4.4. Técnica de detención temprana

Las redes neuronales artificiales aprenden en etapas, pasando de funciones bastante simples a complejas a medida que avanza el entrenamiento, es decir, el error cuadrático medio disminuye con el aumento en el número de etapas durante el entrenamiento: comienza con un valor grande y va disminuyendo lentamente a medida que la red abre paso a un mínimo local en el error, con una buena generalización objetivo, es difícil saber cuando es mejor dejar de entrenar la red.

Se puede identificar el comienzo del sobre ajuste de la red a través del uso de la validación cruzada, dividiendo los datos en el conjunto de entrenamiento y conjunto de validación, el conjunto de entrenamiento se utiliza para entrenar la red, con una pequeña modificación, es detenida de forma periódica para poner a prueba la red, este procedimiento se conoce como detención temprana. En la Figura 3.6 se muestran las dos curvas de aprendizaje, una es el conjunto de entrenamiento y el conjunto de validación. Por lo general, el modelo no muestra muy buenos resultados en el conjunto de validación como

lo hace en el conjunto de entrenamiento de diseño. La técnica de detención temprana propone que el punto mínimo de la curva de aprendizaje de validación se utilice como criterio razonable para detener el entrenamiento de la red [24].

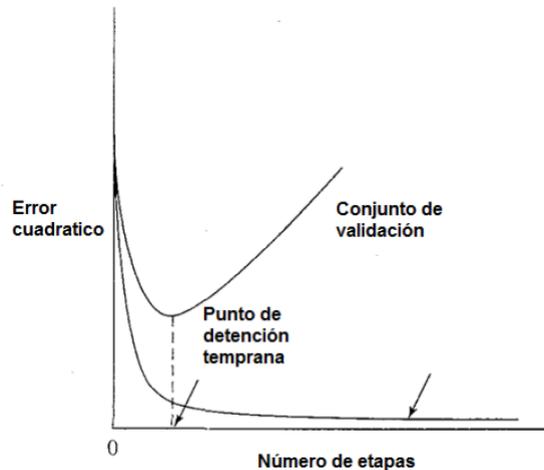


Figura 3.6: Curvas de detención temprana basada en la regla de validación cruzada.

3.2.5. Computación Evolutiva

La computación evolutiva esta basada la teoría de Charles Darwin la evolución de las especies, como un proceso de aprendizaje, para lograr que las diferentes especies se vuelvan más aptos para sobrevivir, en los que por medio de algoritmos se trata de resolver problemas de búsqueda y optimización. Dichos algoritmos son denominados algoritmos evolutivos. Los algoritmos evolutivos han resultado muy éxitos en la solución de una amplia gama de problemas del mundo real.[25]

En términos generales, para simular el proceso evolutivo en una computadora se requiere:

- Codificar las estructuras que se replicaran (una estructura de datos que se utilice para almacenar a un “individuo”).
- Operaciones que afecten a los “individuos” (se usan cruce y mutaciones).
- Una función de aptitud que indique qué tan buena es una solución respecto a las demás.
- Un mecanismo de selección que implemente el principio de “supervivencia del más apto”.

Debido a que hoy en día es difícil diferenciar los diferentes tipos de algoritmos evolutivos, se suelen mencionar tres paradigmas principales:

- Programación Evolutiva (PE)
- Estrategias Evolutivas (EE)
- Algoritmos Genéticos (AG)

3.2.5.1. Programación Evolutiva

Lawrance J. Fogel propuso esta técnica en el cual la inteligencia se ve como un comportamiento adaptativo[26]. La programación evolutiva enfatiza el comportamiento entre padres e hijos y no busca emular operadores genéticos específicos. El algoritmo básico de la programación evolutiva es la siguiente [25]:

- Generar aleatoriamente una población inicial
- Se aplica mutación
- Se calcula la aptitud de cada hijo y se usa un proceso mediante torneo, para determinar cuales soluciones se retendrán.

La programación evolutiva no requiere del uso de un operador de recombinación, asimismo, usa una selección probabilística. El objetivo es hacer que el autómata reconozca un conjunto de entradas sin equivocarse ni una sola vez. Algunas aplicaciones de la programación evolutiva son [27]:

- Predicción
- Generalización
- Juegos
- Control Automático
- Problema del viajero
- Planeación de rutas
- Diseño y entrenamiento de redes neuronales
- Reconocimiento de patrones

3.2.5.2. Estrategias Evolutivas

Las estrategias evolutivas (EE) son algoritmos de optimización que buscan el valor mínimo o máximo de una función, llamada función objetivo [28]. Las EE son muy útiles para problemas no lineales [29], se inspiran en la teoría de la evolución para buscar soluciones a problemas complejos.

Las estrategias evolutivas trabajan con poblaciones de posibles soluciones a un problema, también llamadas soluciones candidato. Estas soluciones candidato son evaluadas de acuerdo a una función de aptitud, que generalmente es la función objetivo del problema de optimización a resolver. Una vez evaluadas, se seleccionan de forma determinista a las mejores soluciones candidato según su aptitud. Esta selección de soluciones se usará para

generar una nueva población de individuos. El principio básico en que se basan las estrategias evolutivas es que los mejores padres de una población generarán hijos que tendrán mejor aptitud que sus padres.

Un punto importante en computación evolutiva, es como representar a las soluciones candidato para un problema. En estrategias evolutivas, todas las soluciones se representan como un vector de números reales. Este vector contiene los parámetros que definen el estado de un sistema. Por ejemplo, la distancia horizontal a la que viaja una bala de cañón, está en función del ángulo de disparo λ , y la resistencia del viento β , de manera que un elemento de la población puede ser representado con un vector $x = [x_1, x_2]$, donde x_1 es un valor dado para λ y x_2 es un valor dado para β . Dados λ y β se puede evaluar la distancia horizontal máxima a la que viaja la bala de cañón usando una fórmula de tiro parabólico. Esta distancia será la aptitud de la solución candidato x .

Una vez generada una nueva población, esta se evalúa y se procede a seleccionar a los padres de la siguiente población. El proceso de selección en las EE es determinista, si se van a elegir a μ futuros padres de una población de λ hijos ($\lambda > \mu$), simplemente se ordenan los μ hijos de mejor a peor de acuerdo a la función de aptitud y se eligen los primeros λ . Existen varias versiones de las estrategias evolutivas dependiendo de la cantidad de padres que generan la siguiente población y si un padre puede pasar a la siguiente generación. En la versión $EE(1+1)$, un padre genera un único hijo y se elige al mejor de los dos como padre de la siguiente generación. En la versión $EE(1, \lambda)$, un padre genera λ hijos y se elige al mejor de los hijos como padre de la siguiente generación. En la versión $EE(\mu + \lambda)$, μ padres generan λ hijos y se elige a los mejores μ elementos de la combinación de padres e hijos. También está la versión $EE(\mu; \lambda)$, que es parecida a la versión $EE(\mu + \lambda)$, con la diferencia de que los μ padres de la siguiente generación eligen exclusivamente de los λ hijos.

Rechnbeg [30] formuló una regla para ajustar la desviación estándar de forma determinista durante el proceso evolutivo, permitiendo que el proceso convergirá hacia el óptimo, esta se conoce como la “ la regla del éxito 1/5, la cual indica: “La razón entre mutaciones exitosas y el total de mutaciones debe ser 1/5. Si es mayor, entonces debe incrementarse la desviación estándar. Si es menor, entonces debe decrecerse”.

Otro punto importante es como recombinar y variar a los elementos de una población para generar nuevas poblaciones. En EE, el elemento más importante para generar una nueva población es la mutación. En la mutación, los elementos de la población son alterados de forma aleatoria, sumando a cada componente x_i de una solución candidato, una cantidad que se elige siguiendo una distribución normal. La cruce entre elementos de la población es considerada como un elemento secundario en la estrategia evolutiva, y se realiza eligiendo un punto intermedio entre dos padres (cruza normal), o más de dos padres (cruza panmítica). Los padres son tomados de forma aleatoria de entre los mejores individuos de la población.

Algunas aplicaciones de las estrategias evolutivas son [31]:

- Problemas de rutas y redes
- Bioquímica
- Óptica
- Diseño en ingeniería
- Magnetismo

3.2.5.3. Algoritmos Genéticos

Los algoritmos genéticos están motivados por el interés en resolver problemas de aprendizaje de máquina. El algoritmo genético enfatiza la importancia de la cruce sexual (operador principal) sobre el de la mutación (operador secundario) y usa una selección probabilística. El algoritmo básico es el siguiente:

- Generar aleatoriamente una población inicial.
- Calcular la aptitud de cada individuo.
- Seleccionar con base a la aptitud.
- Aplicar operadores genéticos para generar la siguiente población.
- Ciclar hasta que cierta condición se satisfaga.

La representación tradicional es la binaria como se muestra en la Figura 3.2.5.3, una cadena binaria es llamada “cromosoma”, el bloque de bits que codifica una sola variable del problema se le denomina “gen” y al valor dentro de cada posición se le llama “alelo” [25].

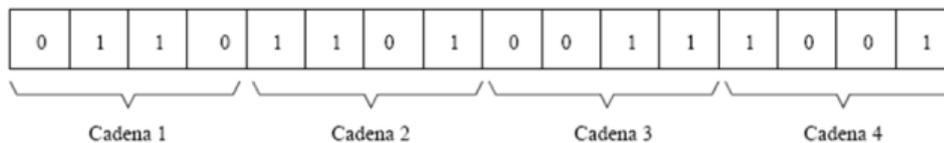


Figura 3.7: Ejemplo de de codificación usada tradicionalmente en los algoritmos genéticos.

En los Algoritmos Genéticos suelen usarse tres tipos principales de cruce: de un punto, de dos puntos y uniforme. Algunas aplicaciones de los algoritmos genéticos son las siguientes [32]:

- Optimización (estructural, de topologías, numérica, combinatoria)
- Aprendizaje de máquina (sistemas clasificadores)
- Bases de datos (optimización de consultas)
- Reconocimiento de patrones
- Generación de gramáticas
- Planeación de movimientos de robots
- Predicción

3.2.5.4. Ventajas de la computación evolutiva

La computación evolutiva tiene diversas ventajas que son importante destacar para resolver problemas de búsqueda y optimización [32]:

- Simplicidad conceptual.
- Amplia aplicabilidad.
- Superiores a las técnicas tradicionales en problemas del mundo real.
- Tiene el potencial para incorporar conocimiento sobre dominio y para hibridarse con otras técnicas de búsqueda/optimización.
- Puede explorar fácilmente las arquitecturas en paralelo.
- Son robustas a los cambios dinámicos.

La computación evolutiva como disciplina, en los últimos años a tenido la atención los investigadores, debido a que se ha tenido un enorme éxito para resolver problemas de gran complejidad.

Capítulo 4

METODOLOGÍA

En este capítulo se presenta de forma detallada y secuencial, el conjunto de pasos propuestos para la automatización y optimización de parámetros de la línea de alimentación de troquelado, desde el análisis del área hasta la implementación del proyecto.

4.1. Metodología propuesta

En este trabajo se basada en el aseguramiento de que es necesario realizar una automatización y la optimización en el proceso y que su implementación se esta efectuando de forma correcta, por lo que el desarrollo e implementación sistemática de estas técnicas, resulten de una metodología la cual se describe en la Figura 4.1 en la que se muestra cada uno de los pasos, los cuales inician con el análisis del área manual, la definición de la automatización, determinación de parámetros del proceso automatizado, búsqueda de un modelo de optimización adecuado, para finalmente validarlo en línea.

Análisis del área: Se realiza el análisis del proceso, con el fin de encontrar los puntos del sistema en los que se pudiera hacer una mejora y en los que es indispensable realizar un cambio total en la operación.

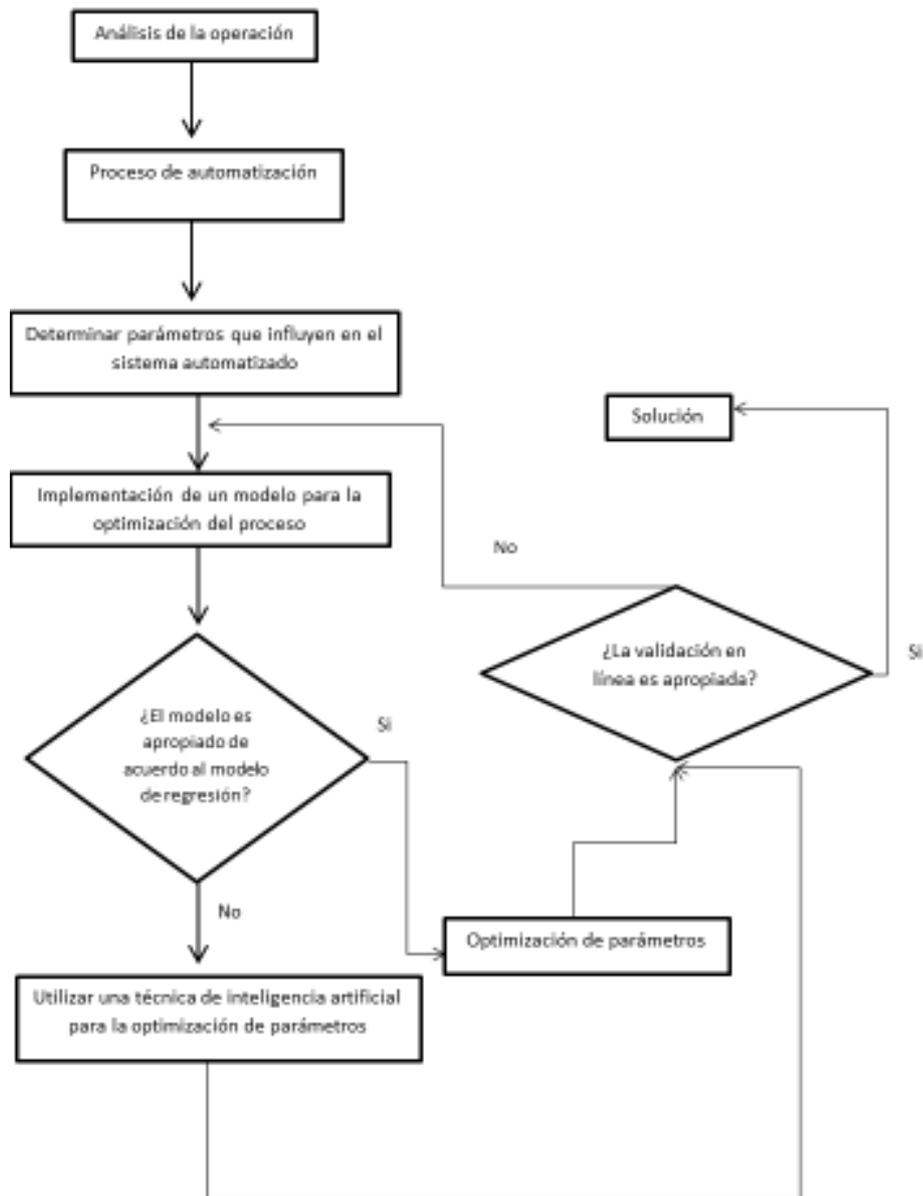


Figura 4.1: Esquema de pasos de la metodología

Proceso de automatización: La automatización esta definida por la elección de los componentes que ayuden a mejorar el proceso, en los diferentes puntos críticos, considerando las operaciones que son indispensables que realice el operador y las que pudiera realizar una máquina, considerando que no se eleve el número de piezas defectuosas y el que realmente genere un beneficio para la empresa.

Determinar los parámetros que influyen en el proceso automatizado: Al realizar la optimización en una línea de producción es necesario hacer un número de pruebas antes de poner en marcha la línea automatizada, en este proceso se determinaron los parámetros que se pueden variar en la maquinaria, para posteriormente utilizarlos para la optimización del proceso y este funcione de manera correcta.

Implementación de un modelo para la optimización del proceso: Este proceso tiene la finalidad de encontrar un modelo por medio del método de diseño de experimentos, el cual se dividió en dos partes, el análisis de regresión y el uso de técnicas de inteligencia artificial.

1. *Análisis de regresión:* En este paso se realizará un análisis del diseño de experimentos por medio del método de regresión, en el cual se determinará si se ajusta a este método, para realizar la operación.
2. *Técnicas de inteligencia artificial:* Es una opción, si el análisis de regresión no se ajusta a un modelo estadístico, se utilizará una red neuronal artificial para ajustar el modelo y posteriormente la optimización por medio de el método de estrategias evolutivas.

Validación en línea: Al término de los estudio se realizará una validación de la optimización el línea de producción, con el fin de comprobar loa valores obtenidos en el sistema.

Capítulo 5

Resultados

En este capítulo se presenta un caso de estudio en el cual se aplicó la metodología en la empresa MAPISA, en el área de troquelado para la pieza denominada “soporte de uña”, que es utilizada como subensamble en los pilotos para calentadores de gas. Se hace una descripción detallada del estudio, el análisis del área para identificar puntos claves en los que se requieran mejoras, la automatización, la identificación de parámetros en la automatización, finalmente la optimización de parámetros y la validación en línea.

5.1. Análisis del área

En el análisis del área se identificaron las piezas que se producen, decidiendo que la pieza denominada “soporte de uña” la cual se muestra en la Figura 5.1, es la de mayor demanda.



Figura 5.1: Soporte de uña.

Considerando que se debe de estudiar cada una de las partes para la formación de la pieza requerida el análisis del proceso se dividió en dos partes: el proceso de troquelado y la simulación en el software Flexim©.

5.1.1. Proceso de troquelado.

El proceso de troquelado para la fabricación del soporte de uña se dividió en seis pasos importantes.

El primero consta de acomodar el rollo de lámina en el porta-rollo como se muestra en la Figura 5.2, siendo activado por el operador por medio de un pedal que controla el motor permitiendo la elongación del rollo para alimentar la prensa. El problema que se detectó durante esta operación es que el operador se tarda entre 30 y 50 minutos en acomodar el rollo y que durante la operación de troquelado el operador acomoda continuamente el rollo dentro del las aspadas del porta rollo debido a que durante la alimentación a la prensa la lámina sobre pasa el límite de las aspadas.



Figura 5.2: Acomodar el rollo.

Posteriormente el operador introduce la lámina en el troquel para empezar la producción de piezas. El operador estira la lamina para que está entre en el troquel como se muestra en la Figura 5.3 Estando la lámina el el troquel el operador por medio de un pedal activa la prensa para que empiece a troquelar. El troquel cuenta con punzones de tope para indicarle al operador el avance de la lámina, este paso depende completamente

del operador y de la habilidad que tenga para realizar las dos operaciones a la vez: estirar la lámina y presionar el pedal, detectando el problema de que el operador para llegar al objetivo durante el proceso se encuentre en una postura poco ergonómica.



Figura 5.3: Alimentación de la prensa.

Durante el proceso en el que el operador alimenta la prensa y sin estar definido por un tiempo específico el operador rocía refrigerante sobre la lámina y el troquel como se muestra en la Figura 5.4. Considerando que es importante la lubricación para reducir el desgaste de herramientas y dados, así como para mejorar la calidad de los bordes, se concluyó que el uso de refrigerante era inadecuado por lo que fue cambiado por un lubricante convencional, aunque prosigue el problema de que este es un proceso a criterio del operador, ya que no está regulado por tiempos ni cantidad.



Figura 5.4: Rocío de refrigerante a la lámina.

Finalmente el proceso termina cuando la pieza sale del troquel en forma de soporte de uña como se muestra en la Figura 5.5, aunque el operador sigue con la responsabilidad de acomodar las piezas que se detienen en la rampa que se encuentra para que caiga en el contenedor.



Figura 5.5: Fin del proceso.

Considerando los pasos de producción se procede a un análisis de tiempos muertos en la alimentación de lámina al troquel en las que se determinaron las siguientes actividades:

- Acomoda el rollo en el porta-rollo.
- Rocía refrigerante.

- Mueve piezas.
- estira y acomoda el rollo de lámina.

Las operaciones realizadas por el operador no producen ningún valor a la operación y podrían ser sustituidas, ya que después de 320 horas de observar la operación se determinó que se pierden alrededor de dos a tres horas diarias en una jornada laboral completa. Los tiempos muertos de la máquina podrían eliminarse, reduciendo de este modo el tiempo de ciclo del soporte tipo uña y la fatiga del operador.

5.1.2. Simulación del sistema

Una vez desarrollado el análisis del proceso de troquelado artesanal se procedió a realizar una simulación en el programa Flexim©, con el fin de obtener el mayor número de datos que intervienen en el proceso y en busca de soluciones que puedan mejorar cada una de las actividades que realiza el operador, en la Figura 5.6 se muestra la simulación del proceso en Flexim© en la que se puede observar como el operador alimenta la prensa y como cada una de las piezas son depositadas en un contenedor, se incluyeron en esta simulación cada uno de los tiempos en el que el operador realiza alguna actividad como: rociar lubricante, acomodar y estirar el rollo y el mover las piezas de la rampa las cuales están representadas con un recuadro amarillo alrededor del proceso de troquelado como se muestra en la Figura 5.7.

Después de realizar la simulación se puede concluir que el proceso artesanal es inestable, y que es necesario buscar mecanismos de automatización para controlar el proceso.

Un punto importante en la simulación es que se determinó que el operador seguirá acomodando los rollos de lámina en el porta-rollo debido a que este es un tiempo muerto que se tiene al inicio de la operación, ya que después de correr diez veces la simulación,

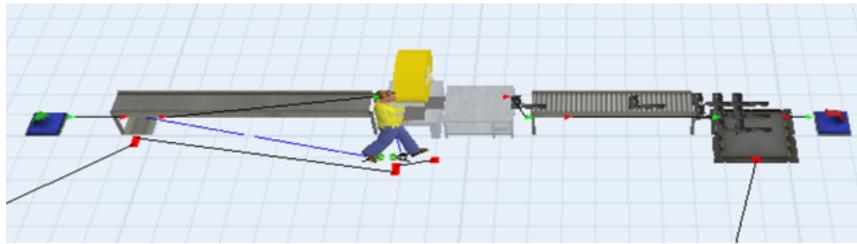


Figura 5.6: Simulación del proceso manual.



Figura 5.7: Actividades extra en el proceso de troquelado.

quitando la actividad de colocar el rollo en el porta-rollo, no se tiene un incremento significativo en las piezas producidas, obteniendo en una hora alrededor de 850 piezas con un tiempo promedio de 10 segundos entre cada pieza.

Con el fin de comprobar si es necesaria la automatización del proceso se hicieron algunas modificaciones en las actividades del operador eliminando las actividades de rociar lámina, acomodar rollo durante el troquelado, acomodar piezas y la alimentación de la lámina a la prensa por medio del operador, considerando que el operador solo realiza el arranque de la maquinaria al inicio de la jornada laboral y los cambios de rollo necesarios. Obteniendo como resultado que después de una hora en tiempo de simulación se tienen 3002 piezas con un tiempo de espera de 4 segundos entre cada pieza, sin tener tiempos muertos. Logrando un beneficio del 400 % en la producción, teniendo una eliminación de tiempos muertos por actividades que no generan ningún tipo de valor en la operación.

Tabla 5.1: Datos técnicos del alimentador electrónico.

Característica	Valor
Ancho máximo de la cinta de lámina	6 pulgadas
Longitud de avance máxima	0 a 99.99 pulg
Calibre máximo de la cinta de lámina con el enderezador incorporado	0.060 pulg.
Diámetro de los rodillos	2.000 pulg.
Precisión a la velocidad de 1,200 pulg./min	± 0.002 pulg.
Rendimiento 60 GPM para una alimentación de	6 pulg.
Conexión eléctrica	220V/1 f /60Hz.

5.2. Automatización

Considerando la necesidad de la automatización en el proceso de alimentación a la prensa se procedió a buscar el equipo diseñado para ayudar a realizar cada uno de los pasos, como el porta-rollo, un sistema de alimentación y enderezado de la lámina y el proceso de lubricado, tomando en cuenta para la adquisición del equipo cada una de las indicaciones que la empresa MAPISA consideró necesarias como: que el equipo no sobrepase las especificaciones de la prensa establecida, el costo, capacitación ofrecida por el vendedor y la facilidad de obtener refacciones en caso de ser necesarias.

A continuación se describen las características del equipo adquirido por la empresa.

1. Alimentador electrónico de rodillos para cintas de lámina con enderezador integrado.

En la Tabla 5.1 se muestran los datos técnicos del alimentador electrónico, y en la Figura 5.8 se muestra una imagen de este.

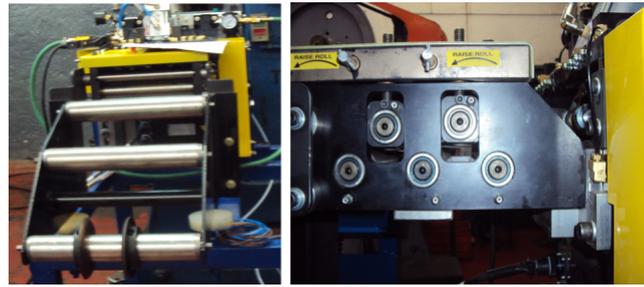


Figura 5.8: Alimentador y enderezador de lámina.

Tabla 5.2: Datos técnicos del porta-rollos tipo pallet.

Característica	Valor
Capacidad de carga	3,500 lbs.
Diámetro de la plataforma	42 pulg.
Diámetro máximo de los rollos de lámina	48 pulg.
Velocidad de la plataforma	0 - 12 o 0 - 24 RPM.
Accionamiento con motor reductor de	20/1 o 10/1
Ancho máximo de la cinta de lámina	6 pulg.
Altura máxima de los rollos con sus tarimas	40 pulg.
Potencia del motor de corriente directa	$\frac{1}{2}$ HP.
Peso del porta-rollos	390 lbs.

2. Porta-rollos horizontal, tipo pallet, para cintas de lámina, marca NORWALK INNOVATION, modelo CR3542, de fabricación estadounidense. En la Tabla 5.2 se muestran los datos técnicos del porta-rollos tipo pallet, y en la Figura 5.9 se muestra una imagen de este.



Figura 5.9: Porta-rollos tipo pallet

3. Aplicador de uso rudo para la alimentación y dosificación forzada de lubricante para cintas de lámina, marca UNIST, modelo uni-Roller RL-3-PF-B-X, de fabricación estadounidense. En la Tabla 5.3 se muestran los datos técnicos del sistema de lubricación, y en la Figura 5.10 se muestra una imagen de este.

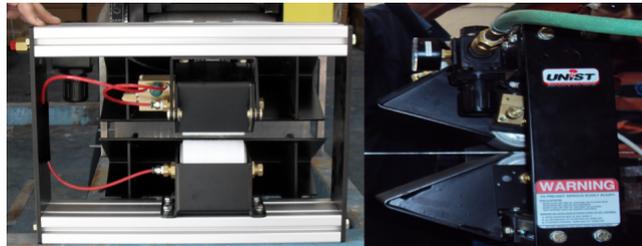


Figura 5.10: Aplicador de lubricante

Antes de la llegada del equipo en la empresa MAPISA se iniciaron los cambios necesarios como: realización del layout del área de troquelado (Anexo I), colocación de pastillas y dispositivos eléctricos para la llegada del equipo.

Tabla 5.3: Datos técnicos del lubricador.

Característica	Valor
Ancho máximo de la cinta de lámina	3 pulg.
Calibre mínimo de la cinta de lámina	0.010 pulg.
Calibre máximo de la cinta de lámina	0.125 pulg.
No. de pares de rodillos aplicadores de lubricante	1
Longitud de los rodillos aplicadores de lubricante	3 pulg.
Espesor de la cubierta de los rodillos	0.25 pulg.
Diámetro de los rodillos aplicadores de lubricante	3 pulg.
Rango de viscosidad @ 100°F (40°C)	100-800 SUS.
Altura de entrada de la lámina	3.51 pulg.
Ancho del aplicador	4.7 pulg.
Largo del aplicador	7.75 pulg.
Altura del aplicador	6.8 pulg.

Finalmente se obtuvo una línea completa de alimentación a la prensa como se muestra en la Figura 5.11, con un sistema de producción automatizado en el que solo hay que incluir los datos de cada uno de los parámetros y realizar el cambio de alimentación en cada uno de los rollos de lámina con la ventaja de que al ser una porta-rollos tipo pallet se pueden tener al mismo tiempo hasta 6 rollos para alimentar a la prensa.

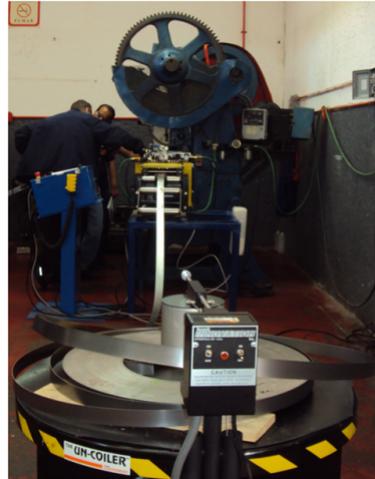


Figura 5.11: Línea de producción automatizada

5.3. Diseño Experimental.

Al tener instalada la maquinaria se ubicaron los parámetros de los que depende el proceso y que se pueden variar para obtener la pieza, los cuales fueron: la velocidad de alimentación de la lámina, la presión de lubricación, el nivel de lubricante y el avance de la lámina, por lo que se decidió hacer un diseño factorial de dos nivel con tres puntos centrales. Se decidió hacer el diseño factorial de dos niveles debido al número de pruebas que se debían realizar y a la disponibilidad del equipo por parte de la empresa, ya que al ser cuatro variables con un número de nivel mayor se elevaban las pruebas.

En la Tabla 5.5 se muestra el diseño de experimentos en el que se tomo como entradas las variables: velocidad de alimentación de la lámina, la presión de lubricación, el nivel de lubricante y el avance de la lámina y como salida el exceso de material en la pieza. Los niveles que se manejaron para cada variables se muestran en la Tabla 5.4:

Posteriormente se realizó un análisis de residuos del diseño de experimentos, ya que como se mencionó en el apartado de diseño de experimento, se debe verificar que el mo-

Tabla 5.4: Niveles utilizados para el DOE

Descripción	Niveles
Velocidad de alimentación	10 y 50 pulgadas/min.
Presión de lubricación	15 y 55 PSI
Nivel de lubricación	1 y 4
Avance de la lámina	1.50 y 3.50 pulgadas
Exceso de material	0.655 (± 0.05)

delo no violen los supuestos básicos: que son el supuesto de normalidad y el supuesto de independencia [13], los cuales se pueden verificar mediante la gráfica de probabilidad normal de residuales mostrada en la Figura 5.12 y la gráfica de los residuales en secuencia del tiempo mostrada en la Figura 5.13, en las cuales se muestra que se cumplen estos supuestos y con lo que se puede decir que el sistema es estable y se puede buscar una forma de optimización.

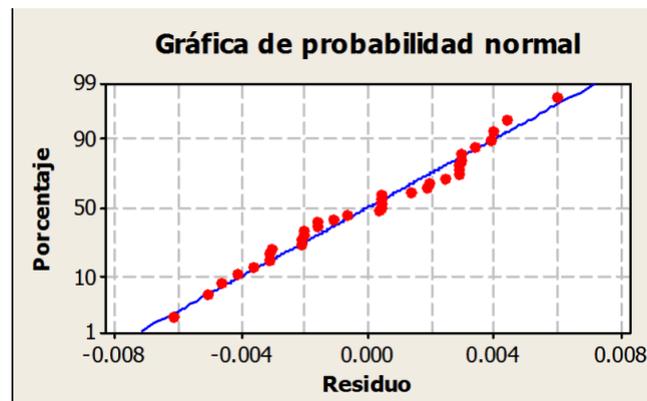


Figura 5.12: Gráfica de probabilidad normal de los residuales.

La Tabla 5.6 muestra el análisis realizado para la obtención de los efectos significativos que son los siguientes:

- Nivel de lubricación

Tabla 5.5: Diseño de experimentos

Velocidad (Pulg./ min)	PresionLub (PSI)	NivelLub (Estado)	Avance (Pulg.)	Exceso de material
10	15	1	1.5	0.657
50	15	1	1.5	0.656
10	55	1	1.5	0.657
50	55	1	1.5	0.647
10	15	4	1.5	0.663
50	15	4	1.5	0.665
10	55	4	1.5	0.666
50	55	4	1.5	0.674
10	15	1	3.5	0.659
50	15	1	3.5	0.665
10	55	1	3.5	0.661
50	55	1	3.5	0.656
10	15	4	3.5	0.666
50	15	4	3.5	0.662
10	55	4	3.5	0.661
50	55	4	3.5	0.671
10	15	1	1.5	0.654
50	15	1	1.5	0.653
10	55	1	1.5	0.664
50	55	1	1.5	0.658
10	15	4	1.5	0.669
50	15	4	1.5	0.659
10	55	4	1.5	0.661
50	55	4	1.5	0.670
10	15	1	3.5	0.667
50	15	1	3.5	0.670
10	55	1	3.5	0.665
50	55	1	3.5	0.650
10	15	4	3.5	0.666
50	15	4	3.5	0.661
10	55	4	3.5	0.670
50	55	4	3.5	0.671
30	35	2.5	2.5	0.656
30	35	2.5	2.5	0.665
30	35	2.5	2.5	0.665

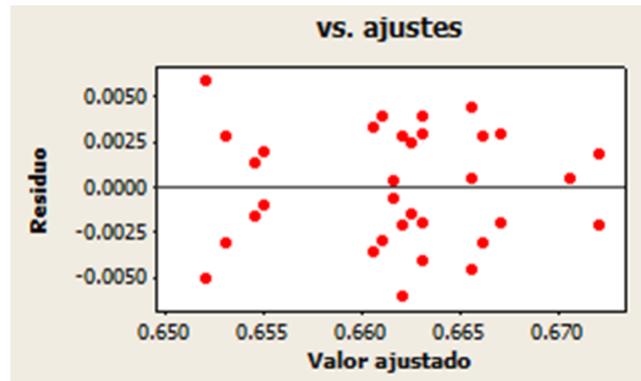


Figura 5.13: Gráfica de los residuales contra el tiempo.

- Avance
- Presión de lubricación y nivel de lubricación
- Velocidad, nivel de lubricación y presión de lubricación

En el análisis de datos se puede observar que considerando el valor P es menor a 0.05 para las variables de nivel de lubricación, avance, presión de lubricación-nivel de lubricación y velocidad-presión de lubricación-nivel de lubricación indicando que estos parámetros son significativos en el modelo. También se que se tiene una R-cuadrada de 76.69%, lo que nos dice sólo se puede explicar el 76% de la variación del modelo, la R-cuadrada(ajustada) es de un 60.36% y la R-cuadrada(predicha) de 27.11%, lo que indica que el modelo no es adecuado ya que una diferencia mayor que 0.20 entre la “R-cuadrada(predicha) y la “R-cuadrada ajustada” indican un posible problema con el modelo y/o los datos[13]. Por lo se puede decir que no es conveniente realizar un análisis de regresión de este modelo y se debe dar a la búsqueda de otras opciones.

Tabla 5.6: Análisis de datos

Término	Efecto	Coef	Coef. de EE	T	P
Constante		0.662114	0.000678	976.07	0.000
Velocidad	-0.001188	-0.000594	0.000709	-0.84	0.413
PresionLub	0.000687	0.000344	0.000709	0.48	0.633
NivelLub	0.007188	0.003594	0.000709	5.07	0.000
Avance	0.003063	0.001531	0.000709	2.16	0.043
Velocidad*PresionLub	0.000187	0.000094	0.000709	0.13	0.896
Velocidad*NivelLub	0.002438	0.001219	0.000709	1.72	0.101
Velocidad*Avance	0.000063	0.000031	0.000709	0.04	0.965
PresionLub*NivelLub	0.003563	0.001781	0.000709	2.51	0.021
PresionLub*Avance	-0.002063	-0.001031	0.000709	-1.45	0.162
NivelLub*Avance	-0.002813	-0.001406	0.000709	-1.98	0.061
Velocidad*PresionLub*NivelLub	0.005563	0.002781	0.000709	3.92	0.001
Velocidad*PresionLub*Avance	-0.001312	-0.000656	0.000709	-0.93	0.366
Velocidad*NivelLub*Avance	-0.000813	-0.000406	0.000709	-0.57	0.573
PresionLub*NivelLub*Avance	0.002313	0.001156	0.000709	1.63	0.119

R-cuad. = 76.69% R-cuad. (pred.) = 27.11% R-cuad. (ajustado) = 60.36%

5.4. Redes neuronales

Realizando una búsqueda de opciones para realizar el modelo de los datos para la optimización de parámetros se procedió a utilizar la técnica de redes neuronales artificiales para hacer la aproximación a la función del modelo tomado del análisis del diseño de experimentos, tomando los 35 experimentos, en los cuales se variaron los valores de las variables críticas y se midió la respuesta como el exceso de material en las piezas. Realizando el procedimiento mencionado en el marco teórico por medio del entrenamiento y la validación de los datos a través de las RNAs.

Se tomaron los valores de la velocidad de alimentación, la presión del lubricante, el nivel del lubricante y el avance de la lámina como entradas a la red y como salida el exceso de material de la pieza. Posteriormente el conjunto de entradas y salidas fue normalizado en un rango de -1 a 1 para facilitar el procedimiento de entrenamiento. El conjunto de

entrenamiento fue dividido en tres grupos el 60 % de los datos se tomó como conjunto de entrenamiento, el 20 % se tomó como conjunto de validación durante el entrenamiento y el 20 % se tomó como conjunto de prueba de la aproximación final, el entrenamiento usa el algoritmo de Levenberg-Marquardt [15], usado en el software Matlab.

La razón para dividir las muestras en los tres grupos antes mencionados, es para evitar que la red neuronal se sobreentrene, es decir, que sea muy efectiva al simular los valores de los datos con los que fue entrenada, pero sea incapaz de reproducir apropiadamente nuevos datos. Para esto se usó el método de detención temprana. Este método consiste en entrenar la RNA exclusivamente con el conjunto de entrenamiento y en cada iteración, medir el error de predicción respecto al conjunto de validación. Conforme la red es entrenada, su error respecto tanto al conjunto de entrenamiento como de validación se reduce, pero llega un momento en que el error respecto al conjunto de validación empieza a incrementarse mientras que el error respecto al conjunto de entrenamiento sigue bajando. Es en este momento cuando se considera que la red se está sobreentrenando y se detiene el entrenamiento.

El conjunto de prueba se usa como una verificación final de la capacidad de predicción de la RNA. Con respecto a la topología usada la red neuronal artificial tienen cuatro entradas siendo las variables críticas independientes; una variable de salida correspondiente al exceso de material en las piezas, así se tiene una capa de salida con una neurona. Se utilizó como función de transferencia una tangente-sigmoide en la capa oculta y una lineal en la capa de salida.

Para determinar el número de neuronas a usarse en la capa oculta, se corrieron varios experimentos en el entrenamiento de la red usando 3, 4, 5, 6, 7 y 8 neuronas en la capa oculta, para posteriormente calcular el error entre la salida de la red y las salidas de la

muestra y elegir el que daba el menor error. El número de neuronas con el mínimo error es cinco, con un error de 0.0032 entre los datos de entrenamiento y los datos de validación.

Como se mencionó anteriormente, la muestra inicial se divide en tres partes: el conjunto de entrenamiento, con el cual se entrena la RNA; el conjunto de validación, que se usa durante el entrenamiento para evitar que la red se sobreentrene; y el conjunto de prueba, que se utiliza para verificar la generalidad de la red. Una vez que la red es entrenada, se usa un análisis de regresión entre la salida de la red y la salida esperada de la muestra, obteniendo como resultados de la validación que el conjunto de entrenamiento tiene un ajuste de 91 %, el de validación de 80 %, el de prueba 81.5 % y el de la combinación de los tres conjuntos es de 81.6 %, como se muestra en la Figura 5.14.

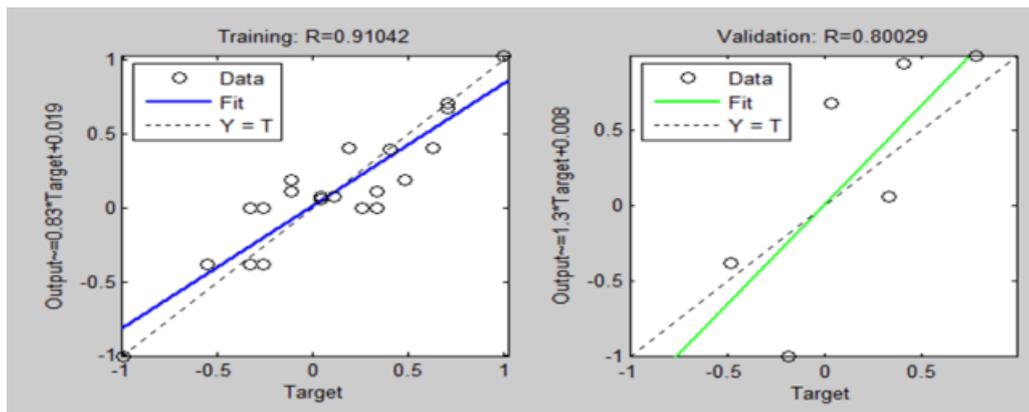


Figura 5.14: Análisis de regresión para el entrenamiento de la RNA. La figura de la derecha muestra el conjunto de entrenamiento y la figura de la izquierda muestra el conjunto de validación

Finalmente de la aproximación a la función se obtienen los pesos y los sesgos los cuales son los siguientes: $w_{11}^1 = 3.4101$, $w_{12}^1 = -7.3347$, $w_{13}^1 = -5.7098$, $w_{14}^1 = 2.8351$, $w_{21}^1 = -3.5324$, $w_{22}^1 = -6.8407$, $w_{23}^1 = -5.9071$, $w_{24}^1 = -5.1624$, $w_{31}^1 = -3.2858$, $w_{32}^1 = 4.6372$, $w_{33}^1 =$

5.8166, $w_{34}^1 = 9.6863$, $w_{41}^1 = 4.3856$, $w_{42}^1 = 1.3599$, $w_{43}^1 = -0.5230$, $w_{44}^1 = -9.2366$, $w_{51}^1 = -10.3093$, $w_{52}^1 = 0.6647$, $w_{53}^1 = -14.5319$, $w_{54}^1 = -8.6639$, $b_1^1 = 2.1697$, $b_2^1 = -0.3887$, $b_3^1 = 6.2122$, $b_4^1 = 6.3527$, $b_5^1 = 5.0958$, $w_{11}^2 = -4.5404$, $w_{12}^2 = 5.1254$, $w_{13}^2 = 6.2084$, $w_{14}^2 = 2.2233$, $w_{15}^2 = -3.7693$, $b_1^2 = -0.0973$, donde w_{ij}^k representa el peso ij de la matriz en la capa k . Los índices ij se refieren a la señal que viene de la neurona j de la capa $k - 1$ a la neurona i de la capa k . Además b_i^k representan el sesgo de la neurona i en la capa k . En la Figura 5.15 se muestra la arquitectura de la red neuronal artificial, donde se puede observar que se tienen dos capas, siendo la primera capa la capa oculta y la segunda capa la capa de salida, de donde se obtiene la siguiente función:

$$f(x) = \text{lineal}(W^2 * \text{tangsigmoide}(W^1 * x + b^2) + b^1) \quad (5.1)$$

Donde *lineal* es una función lineal que regresa el mismo valor que recibe. *tangsigmoide* es la función hiperbólica tangente sigmoide que está definida como se muestra en la ecuación 5.2. W^2 son los pesos de la capa dos. W^1 son los pesos de la capa uno. b^2 son los sesgos de la capa dos. b^1 son los sesgos de la capa uno.

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (5.2)$$

Además, x de la ecuación 5.1 es un vector de cuatro elementos $x = \langle x_1, x_2, x_3, x_4 \rangle$, donde x_1 : es la velocidad de alimentación, x_2 es la presión de lubricación, x_3 es el nivel de lubricante y x_4 es el avance.

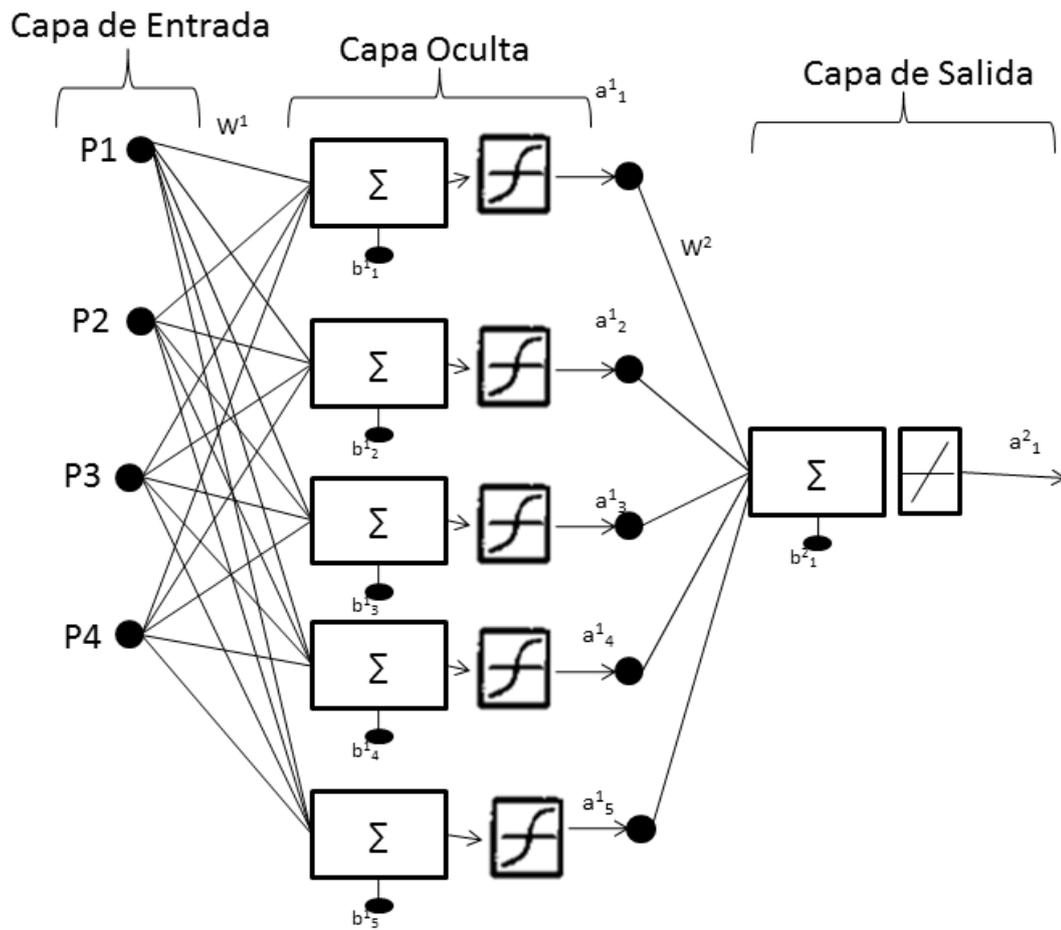


Figura 5.15: Topología de la RNA final

Con esta información se tiene el modelo de los datos por lo que el paso siguiente es obtener la optimización del modelo minimizando el exceso de material en la pieza.

5.5. Optimización a través de estrategias evolutivas

Con la función que se obtuvo de la red neuronal se puede plantear el problema de optimización de la siguiente manera:

$$\text{Minimizar : } f(x) = \text{lineal}(W^2 * \text{tangsigmoide}(W^1 * x + b^2) + b^1) \quad (5.3)$$

Sujeta a:

$$10 \leq x_1 \leq 30$$

$$15 \leq x_2 \leq 35$$

$$1 \leq x_3 \leq 4$$

$$1.5 \leq x_4 \leq 3.5$$

Las restricciones sobre las x están determinados por los valores de la maquinaria adquirida.

Con esta función se hizo un híbrido para la optimización del modelo por medio de la técnica de estrategia evolutiva. Usando la estrategia evolutiva propuesta por Schewefel [31], el cual introdujo múltiples hijos, la cual se denomina: $EE(\mu; \lambda)$.

El procedimiento para la estrategia evolutiva es el siguiente:

- Se utiliza una representación de números reales para las posibles soluciones (en este caso es el vector x).
- Se utiliza una función de aptitud (en este caso es la función de la RNA).

- Se crear una población inicial de soluciones (normalmente es un proceso aleatorio).
- Se utilizan los operadores de búsqueda de EE. En este caso se utilizó la técnica panmítica.
- Se utilizó para la variable x un operador de mutación.
- Se calcula la aptitud de cada hijo.
- Se eligen los mejores hijos para que sean los padres de la siguiente generación.
- Una vez que el algoritmo termina de iterar, se toma el individuo que tenga el valor más pequeño, lo que indicará que se tiene menor exceso de material en la pieza.

Se programó una $EE(\mu; \lambda)$, con $\lambda = 100$ y $\mu = 400$. El algoritmo se corrió por 1000 generaciones. La función objetivo a optimizar fue la RNA ajustada.

Después de correr la estrategia evolutiva en 10 ocasiones, se tomó el mejor valor generado que consistió en la siguiente combinación de parámetros: velocidad de alimentación = 24 pulgadas por minuto; presión de lubricación = 29 psi; nivel de lubricante = 1; avance = 1.5 pulgadas, con un valor de exceso de material de 0.6624. Como una estimación de la variabilidad de los resultados del algoritmo evolutivo se calculo la desviación estandar (σ) de la salida de las diez corridas y esta fue de 0.0104.

Estos parámetros se implementaron en la línea de producción para su validación, obteniendo como resultado final una línea de alimentación sincronizada y con parámetros adecuados, en los que finalmente se tuvieron por hora 3652 piezas se soporte de uña.

Capítulo 6

Conclusiones y trabajo futuro

6.1. Conclusiones

El objetivo de este trabajo se ha centrado en cuatro puntos importantes para el diseño de la automatización y optimización de la línea de alimentación a prensas:

- Análisis del área de trabajo.
- Automatización del proceso.
- Modelo de sistema automatizado.
- Optimización del sistema automatizado.

Estos cuatro puntos obtuvieron buenos resultados de los cuales se obtuvo lo siguiente:

1. **Análisis del área de troquelado:** El análisis del área permitió identificar los puntos críticos de la alimentación manual del sistema, en el que se puede hacer un cambio de refrigerante por lubricante en el proceso y en el se identificó la necesidad de automatizar el proceso, eliminando acciones que no generan valor agregado a la actividad y que permitirán generar un mayor número de piezas en menor tiempo, generando un área de oportunidad a la empresa para incrementar sus ventas.

2. **Automatización del proceso:** Se realizó la búsqueda de proveedores, de maquinaria para alimentación a prensas, se identificó el tipo de máquina necesaria para ser instalada en la línea de producción, así como requerimientos técnicos, espacios y que se ajustaran a la prensa que se tenía, logrando la instalación de en planta y realizando las primeras pruebas para la identificación de parámetros necesarios para el funcionamiento en buenas condiciones.
3. **Modelo de sistema automatizado:** Se realizaron las pruebas necesarias para la identificación de variables de los que depende el proceso automatizado, por medio de un diseño de experimentos. en el cual se confirmó que el proceso debe de utilizar técnicas de inteligencia artificial para la obtención de parámetros adecuados para el proceso de troquelado.
4. **Optimización del proceso automatizado:** La optimización del proceso se llevó acabo por medio de redes neuronales y estrategias evolutivas, obteniendo como puntos óptimos para las variables: velocidad del alimentador, el avance de la lámina, la presión y nivel de refrigerante, teniendo como resultado el mínimo exceso de material en la pieza. Realizando la validación en línea se comprobó que los resultados de la automatización de la alimentación a la prensa permitiendo tener al final del proceso 3652 piezas por hora. Mejorando el objetivo general de tener un incremento útil del en la producción de un 20 %, logrando tener un 40 % en el tiempo útil.

6.2. Trabajo futuro

Esta trabajo puso en evidencia que por medio del uso la investigación automatización y la implementación de parámetros óptimos por medio de inteligencia artificial en líneas de producción se pueden mejorar los sistemas actuales. Sin embargo, es necesario desarrollar trabajo futuro en las siguientes areas:

- El uso de técnicas estadísticas diferentes a la de regresión para comprobar los resul-

tados y hacer una comparación en línea de producción.

- Buscar otros tipos de redes neuronales artificiales para aproximar los valores.
- Probar otros métodos de optimización para la red neuronal artificial.
- Realizar la investigación en otros procesos manuales para comprobar, que por medio de la automatización y optimización con el uso de redes neuronales, se pueden utilizar en diferentes procesos industriales.
- Realizar un análisis a los componentes del troquel para identificar el desgaste en los punzones después de la automatización.
- Hacer modificaciones para que la RNA se este entrenando durante el proceso y los valores de los parámetros se modifiquen automáticamente.

Bibliografía

- [1] Y.Dequan, Z. Rui, C. Jun y Z. Zhen. Research of knowledge-based system for stamping process planning. *The International Journal of Advanced Manufacturing Technology*. 2006, Vol. 29.
- [2] F. Fandón, J.Cerón, D. Valencia. Diseño de troqueles de estampación mediante modelado sólido. Recuperado el 2 de febrero de 2009
- [3] R.D. Jiang, B.T. Lauw and A.Y.C. Nee. Insert design automation for progressive dies.*The International Journal of Advanced Manufacturing Technology*.(2005). Volumen 28.
- [4] S. Tumkor and K. Pochiraju. Progressive Die Strip Layout Optimization for Minimum Unbalanced Moments. *Journal of Manufacturing Science and Engineering*. APRIL 2010, Vol. 132.
- [5] A.Y.C. Neea and V.C. Venkatesha. A Heuristic Algorithm for Optimum Layout of Metal Stamping Blanks. (2008)
- [6] A. Yanagida and A. Azushima. Evaluation of coefficients of friction in hot stamping by hot flat drawing test. *CIRP Annals Manufacturing Technology* 2009. 58: 247–250.
- [7] A. Verl, U. Heisel, M. Walther and D. Maier.Sensorless automated condition monitoring for the control of the predictive maintenance of machine tools. 2009.

- [8] G. Ambrogio, L. Filice y F. Gagliardi. Improving industrial suitability of incremental sheet forming process. *The International Journal of Advanced Manufacturing Technology*. 2011
- [9] J. Hurtado y D.Álvarez. Optimización basada en confiabilidad por medio de redes neuronales y algoritmos evolutivos. *Revista internacional de métodos numéricos para cálculo y Diseño en ingeniería*. 2002.
- [10] M. Balizinki, E. Czogala, K. Jemielniak, J. Leski. Tool condition monitoring using artificial intelligence methods. *Engineering Applications of Artificial Intelligence*.(2002).
- [11] S. Jin, W. Cai, X. Lai,Z. Lin. Design automation and optimization of assembly sequences for complex mechanical systems, Springer-Verlag London.2009.
- [12] Kalpakjan Serope y R. Schmid Seteven. *Manufactura, Ingeniería y Tecnología*.Pearson Education, Cuarta Edición. 2002.
- [13] Montgomery, Gouglas. (2005). *Diseño y análisis de experimentos*. Limusa Wiley. México.
- [14] William Mendenhall, Robert J. Beaver y Barbara M. Beaver.(2008). *Introducción a la probabilidad y estadística*. Thomson.Décimo segunda edición.
- [15] Marcelo Bosque.(2002). *Understanding 99 % of artificial neural networks. Introduction & Tricks*. iUniverse,Inc.
- [16] José C. Principe, Neil R. Euliano, Wcirt Lefebvre. (2000).*Neural and adaptive systems, fundamentals through simulations*.John Eiley & Sons, inc. pag. 68-71;224-229.
- [17] W. McCulloch and W. Pitts. A logical calculus of the ideas immanent in nervous activity. In *Bulletin of Mathematical Biophysics*. 5: 115-133. (1943).

- [18] F. Rosenblatt. The perceptron: A probabilistic model for information storage and organization in the brain. In *Psychological Review*. 65: 386-408. (1958).
- [19] Widrow, B. and Hoff, M.E. Adaptive switching circuits. In 1960 IRE WESCON Convention Record. IRE Part 4: 96-104. (1960).
- [20] Minsky, M. and Papert, S. *Perceptrons*. MIT Press. Cambridge, MA. (1969).
- [21] 15. Hagan, M.T., Demuth, H.B. and Beale, M. *Neural Network Design*. PWS Publishing Co., Boston, Ma. (1997).
- [22] Hornik, K.M., Stinchcombe, M. and White, H. Multilayer feedforward networks are universal approximators. *Neural Networks*, 2: 359-366. (1989).
- [23] Werbos, P.J. *Beyond regression: New tools for prediction and analysis in the behavioral sciences*. PHD Thesis, Harvard University, Cambridge, MA. (1974).
- [24] Simon Hykin. (1999). *Neural networks a comprehensive goundation*. Prentice-Hall. pag. 212-219.
- [25] L. Santana y C. Coello. Una introducción a la computación evolutiva y algunas de sus aplicaciones en economía y finanzas. *Revista de métodos cuantitativos pra la exonomía y la empresa*. 2006 Vol. 2. pag. 3-26.
- [26] L.J. Fogel, A. J. Owens y M. J. Walsh. *Artificial Intelligence through Simulated Evolution*. John Wiley & Sons, Inc. New York 1966.
- [27] D.B. Fogel. *Evolutionary Computation. Toward a New Philisophy of Machine Intelligence*. The Institute of Electronic Engineers. New YOrk 1995.
- [28] Hans-Paul Schewefel, *Evolution and Optimum Seeking: The Sixth Generation*, John Wiley and Sons, Inc. 1993, New York, Usa.

- [29] David E. Goldberg, Genetic Algorithms in Search, Optimization, and Machine learning, 1989, Addison Wesley, Boston MA.
- [30] I. Rechenbeg. Evolutinstrategie: Optimierung technischer Systeme nach Prinzipien der biologischen Evolution. Frommann-Holzboog. 1973. Stuttgart, Alemania.
- [31] H.P. Schewefel. Numerische Optimierung von Computer-Modellen mittels der Evolutionsstrategie. 1977. Basel, Alemania.
- [32] D. E. Goldberg. Genetic Algorithms in Search, Optimization and Machine Learning. Addison-Wesley.1989. Reading, Masachuseets.

Capítulo 7

Anexos

7.1. Anexo I

Layout del área de troquelado MAPISA.

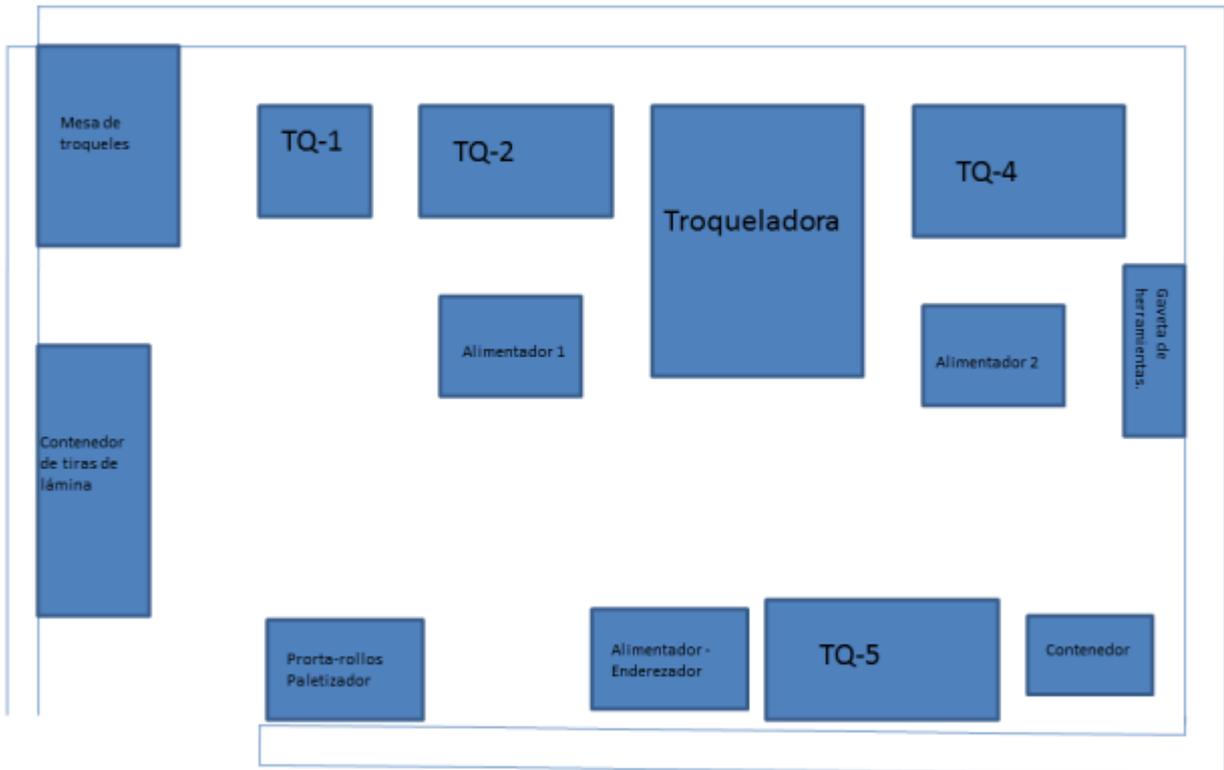


Figura 7.1: Layout área de troquelado con sistema automatizado

7.2. Anexo II

Publicación en el Congreso Mexicano de Inteligencia Artificial (COMIA 2011)

Optimización de Parámetros de una Línea de Estampado Usando Redes Neuronales y Estrategias Evolutivas

Susana Gutiérrez, Giovanni Lizárraga, Marco Jimenez.

Corporación Mexicana de Investigación en Materiales S.A. de C.V, Ciencia y Tecnología
790, 25290, México.

{sgutierrez@comimsa.com, glizarraga@comimsa.com, marcojimenez@comimsa.com}

Resumen. Actualmente, en la industria manufacturera tener procesos eficientes y eficaces es muy importante debido a que proporcionan estabilidad permitiendo la calidad en los productos. La optimización de parámetros esenciales en los sistemas de alimentación de prensas permite que estas trabajen de una mejor forma, incrementando el tiempo de vida de los dispositivos involucrados como máquinas y troqueles. En este artículo se usan redes neuronales artificiales para modelar un sistema de troquelado, para posteriormente realizar la optimización de parámetros por medio de estrategias evolutivas, con el objetivo de lograr la mejor sincronización de los equipos en la producción de piezas del sistema de estampado estudiado.

Palabras Clave: Redes neuronales artificiales, Sistema de estampado, Alimentación de prensas, Estrategias evolutivas.

1 Introducción

El estampado de metales ayuda a la formación de hojas o láminas permitiendo obtener productos esenciales para la vida diaria como es el caso de escritorios, archiveros, carrocerías de autos, fuselajes de aviones, latas de bebidas, joyería, entre otros [1]. En el estampado se utilizan prensas para que por medio de la presión se pueda formar la pieza requerida. En el proceso de estampado y conformado de metales se sigue una serie de pasos que permiten obtener productos de forma específica, este proceso inicia con la lámina ya sea en rollo o placa, para posteriormente realizar diferentes operaciones por ejemplo: el ranurado, corte, serrado o enderezado, después se procede al formado de la pieza mediante troqueles (punzones, dados) ya sean éstos compuestos, progresivos o de transferencia. En la operación de troquelado se pueden realizar las siguientes operaciones: punzonado, corte de piezas, estampado, doblado, formado de rodillos, embutido, entre otros. Finalmente se procede a la limpieza de la pieza y la pintura en caso de ser necesario. Debido a la complejidad del proceso de troquelado se requiere un estricto control en cada uno de sus pasos.

La industria manufacturera depende de que sus procesos de estampado y conformado sean eficaces para mantenerse en el mercado en forma competitiva, con

este fin las empresas utilizan maquinaria automatizada como: porta-rollos, enderezadores, empujadores, lubricadores, pero esto no es suficiente debido a que estas máquinas independientes unas de otras.

Al realizar la automatización de un proceso, como por ejemplo la alimentación de un troquel, es frecuente que aparezcan varios parámetros que requieren ser sincronizados y optimizados para que el sistema automatizado opere de manera óptima. En muchas ocasiones, la sincronía y optimización de los parámetros se hace a prueba y error y no se sigue la metodología científica. El objetivo es la optimización de la alimentación a una prensa utilizada en el proceso de troquelado, mediante la sincronización de cada una de las máquinas que intervienen en la alimentación a la prensa. Con la finalidad de lograr el objetivo del trabajo se utilizó una red neuronal y el método de estrategias evolutivas, considerando como variables principales: la velocidad de alimentación, la presión de lubricación, el nivel de lubricación y el avance de la lámina a la prensa.

En la literatura se pueden encontrar varios temas utilizados para la solución de problemas en los sistemas de estampado como el tomado por Fadón et al. [2], en el que se muestra el proceso de diseño de un troquel basados en la animación por medio del modelado sólido, en el cual se diseñaron las piezas que componen el ensamblaje y posteriormente se realizó una simulación lo que les permitió obtener una animación del funcionamiento del troquel. Considerando que el estampado de metal en blanco depende de la habilidad del operador A.Y.C. Neea and V.C. Venkatesha [3] desarrolló un algoritmo heurístico para optimizar el material, teniendo en cuenta factores como el mínimo desperdicio de material, corrección de la anchura de la lámina y su orientación, proporcionando información sobre la alineación y precisión del centro de la prensa. Yanagida y Azushima [4] desarrollaron un estudio con el fin de medir el coeficiente de fricción del estampado en caliente utilizando una simulación numérica mediante elemento finito, con el fin de disminuir la carga y el desgaste en el proceso de estampado evaluando en el sistema de estampado las condiciones de lubricado y los lubricantes que se usan en forja caliente. En el estudio para la optimización de parámetros en diferentes áreas se encontró la investigación de Jorge Hurtado [5], la cual estudia los parámetros en el diseño de estructuras complejas utilizando estructuras metálicas, con el fin de simplificar el trabajo se utilizan redes neuronales artificiales (RNA) para representar el comportamiento del sistema, para posteriormente combinarlo con algoritmos evolutivos (AE) como método de optimización global de las funciones considerando condiciones de probabilidad. Para el estudio de desgaste Marek Balazinski [6], utiliza 3 métodos de inteligencia artificial para estimar el desgaste de la herramienta en un torno realizando una comparación entre los métodos llamados “convencionales” (redes neuronales y lógica difusa) con la propuesta del autor. Esta propuesta consiste en usar una combinación de red neuronal de retro-propagación y el método de lógica difusa para determinar el desgaste de la herramienta por medio de la fuerza de corte.

En los artículos mencionados, se puede observar que no se ha considerado la alimentación de prensas como un punto importante en la formación de productos, a pesar de que éste se encuentra antes de la fabricación y que contribuye en evitar el desgaste de los herramientas y el desperdicio de material en el proceso. Por lo que se decidió probar un sistema que hace uso de redes neuronales y estrategias evolutivas para ajustar los parámetros de un sistema de alimentación de un troquel.

Debido a que este es un trabajo de aplicación, nos enfocamos en usar técnicas básicas y bien establecidas de inteligencia artificial, con la idea de partir de las técnicas más sencillas y dependiendo de los resultados, continuar con técnicas más avanzadas. Por ejemplo, una red "feedforward" con una capa oculta y estrategias evolutivas, son dos herramientas clásicas en inteligencia artificial que han sido usadas con éxito con anterioridad y cuya implementación es sencilla. Por lo que se consideraron estas técnicas como herramientas iniciales para resolver el problema.

El resto del artículo se organiza como sigue: en la Sección 2, se da una explicación de las redes neuronales artificiales. En la Sección 3, se explica en qué consiste el método de optimización a través de estrategias evolutivas. En la Sección 4, se muestra un caso de aplicación de estas metodologías de inteligencia artificial para ajustar parámetros. Finalmente, en la Sección 5, se dan las conclusiones.

2 Redes Neuronales Artificiales

2.1 Conceptos Generales

El estudio de redes neuronales artificiales es parte de la inteligencia artificial. Las redes neuronales artificiales son sistemas inspirados en el cerebro humano, que se utilizan para aproximar funciones o a la clasificación de patrones, entre otros usos. Los estudios en RNA empezaron con el trabajo de McCulloch y Pitts [7] y fue seguido por Rosenblatt [8], Widrow y Hoff [9], Minsky y Papert [10], y muchos otros.

Un ejemplo de una RNA se puede ver en la Figura 1, donde podemos ver algunos de los elementos de una RNA.

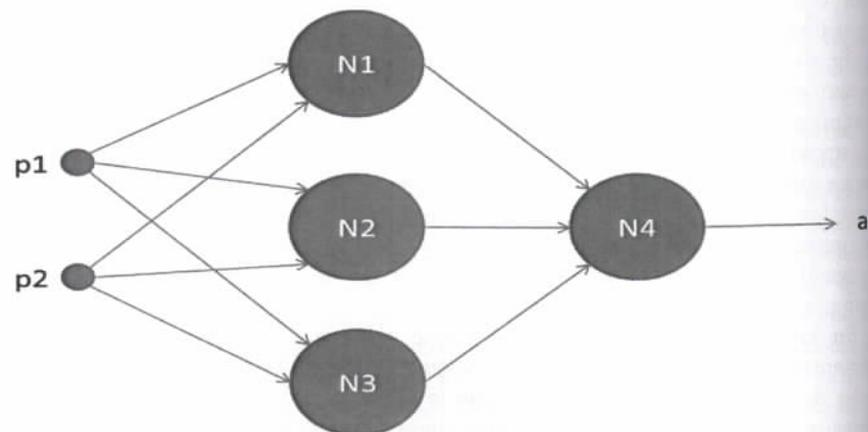


Figura 1. Ejemplo de una red neuronal artificial

En este ejemplo tenemos dos valores de entrada representada por P1 y P2, pero una RNA puede tener cualquier número finito de entradas. Las neuronas en esta red están representadas por los círculos N1, N2, N3 y N4. Las neuronas N1, N2, N3 forman la primera capa de la red. La primera capa recibe y procesa las entradas de la red, y transmite una salida a la segunda capa. La segunda capa consiste en N4. En este ejemplo, la segunda capa recibe los resultados de la primera capa y devuelve la salida de la red (a). Esta red representa una función que recibe dos valores (P1 y P2) y devuelve un valor (a), las RNA puede tener varias capas. La última capa se conoce como capa de salida y devuelve la respuesta de la red a los patrones de entrada. Las capas entre la capa de salida y las entradas se llaman capas ocultas. Las capas ocultas hacen la mayor parte del trabajo cuando se aproxima una función. Cada capa de una RNA, incluyendo la capa de salida, puede tener un número arbitrario de neuronas. Cada neurona de una capa transmite una señal a cada neurona de la capa siguiente. Esta topología se inspira en la forma en que las neuronas están interconectadas en el cerebro.

La topología general de una neurona en una RNA se muestra en la Figura 2.

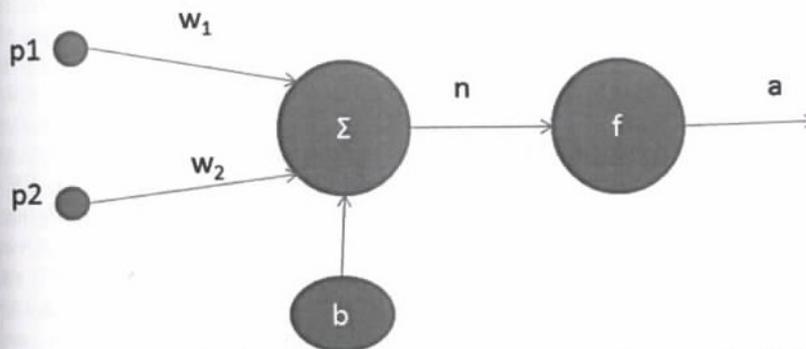


Figura 2. Topología general de una neurona en una red neuronal artificial.

En esta figura se puede observar que una neurona recibe dos entradas p1 y p2. Las entradas pueden ser los valores de entrada a la red, o las salidas de las capas anteriores. Cada entrada se multiplica por un peso w_{ij} , donde i es el número de la neurona que recibe la entrada y j es el número de la neurona que envía la señal. Estas multiplicaciones se suman junto con otro peso b , también llamado sesgo. El resultado de esta suma se llama n , el cual es modificado por una función f , la cual se conoce como función de transferencia. Finalmente, la evaluación de la función de transferencia es la salida "a" de la neurona.

Se ha demostrado que una RNA con dos capas de neuronas puede aproximar cualquier función en cualquier grado, siempre y cuando se tengan suficientes neuronas en la capa oculta. Para este fin, la capa oculta debe tener una función de transferencia monótona creciente y acotada, y la capa de salida debe utilizar una función de transferencia lineal[11]. Sin embargo, es necesario estimar el número de neuronas en la capa oculta. Los datos obtenidos de las muestras deben semejar a

una función de cualquier grado por lo que es posible utilizar redes neuronales artificiales para estimar una población mayor de datos.

2.2 Entrenamiento de la Red Neuronal Artificial.

La predicción de la red neuronal artificial está basada en el ajuste de pesos, para así aproximar la función deseada. Una ventaja de las RNAs es su facilidad de “aprender” los valores para los pesos siguiendo las reglas de aprendizaje. Una de las reglas es el procedimiento de calibración de los parámetros de la red hasta que se tiene una aproximación deseada.

Para las redes multicapa el procedimiento de entrenamiento es el algoritmo de retro-propagación [12]. Para el entrenamiento de la red es necesario un conjunto inicial, se necesita un conjunto de entrada $\{p_1, p_2, \dots, p_n\}$ para los valores de entrada (donde p_i puede ser un vector) y el conjunto correspondiente a $\{t_1, t_2, \dots, t_n\}$ considerado como los valores de salida. El entrenamiento consiste en tener el menor error entre las salidas de la red y las salidas esperadas t_i .

3 Estrategias Evolutivas

Las estrategias evolutivas (EE) son algoritmos de optimización que buscan el valor mínimo o máximo de una función, llamada función objetivo [13]. Las EE son muy útiles para problemas no lineales y forman parte de los diversos paradigmas de la computación evolutiva al igual que los algoritmos genéticos [14], se inspiran en la teoría de la evolución para buscar soluciones a problemas complejos. En las EE varios conceptos presentes en la teoría de la evolución como son: mutaciones, cruza entre individuos, selección natural, supervivencia del más apto, etc. son adaptados para su uso en un programa de computadora.

Las estrategias evolutivas trabajan con poblaciones de posibles soluciones a un problema, también llamadas soluciones candidato. Estas soluciones candidato son evaluadas de acuerdo a una función de aptitud, que generalmente es la función objetivo del problema de optimización a resolver. Una vez evaluadas, se seleccionan de forma determinista a las mejores soluciones candidato según su aptitud. Esta selección de soluciones se usará para generar una nueva población de individuos. El principio básico en que se basan las estrategias evolutivas es que los mejores padres de una población generarán hijos que tendrán mejor aptitud que sus padres.

Un punto importante en computación evolutiva, es como representar a las soluciones candidato para un problema. En estrategias evolutivas, todas las soluciones se representan como un vector de números reales. Este vector contiene los parámetros que definen el estado de un sistema. Por ejemplo, la distancia horizontal a la que viaja una bala de cañón, está en función del ángulo de disparo α , y la resistencia del viento β , de manera que un elemento de la población puede ser representado con un vector $x = [x_1, x_2]$, donde x_1 es un valor dado para α y x_2 es un valor dado para β . Dados α y β se puede evaluar la distancia horizontal máxima a la que viaja la bala de cañón usando una fórmula de tiro parabólico. Esta distancia será la aptitud de la solución candidato x .

Otro punto importante es como recombinar y variar a los elementos de una población para generar nuevas poblaciones. En EE, el elemento más importante para generar una nueva población es la mutación. En la mutación, los elementos de la población son alterados de forma aleatoria, sumando a cada componente x_i de una solución candidato, una cantidad que se elige siguiendo una distribución normal. La cruce entre elementos de la población es considerada como un elemento secundario en la estrategia evolutiva, y se realiza eligiendo un punto intermedio entre dos padres (cruza normal), o más de dos padres (cruza panmítica). Los padres son tomados de forma aleatoria de entre los mejores individuos de la población.

Una vez generada una nueva población, esta se evalúa y se procede a seleccionar a los padres de la siguiente población. El proceso de selección en las EE es determinista, si se van a elegir a μ futuros padres de una población de λ hijos ($\lambda > \mu$), simplemente se ordenan los μ hijos de mejor a peor de acuerdo a la función de aptitud y se eligen los primeros λ . Existen varias versiones de las estrategias evolutivas dependiendo de la cantidad de padres que generan la siguiente población y si un padre puede pasar a la siguiente generación. En la versión EE(1+1), un padre genera un único hijo y se elige al mejor de los dos como padre de la siguiente generación. En la versión EE(1, λ), un padre genera λ hijos y se elige al mejor de los hijos como padre de la siguiente generación. En la versión EE($\mu + \lambda$), μ padres generan λ hijos y se elige a los mejores μ elementos de la combinación de padres e hijos. También está la versión EE($\mu; \lambda$), que es parecida a la versión EE($\mu + \lambda$), con la diferencia de que los μ padres de la siguiente generación se eligen exclusivamente de los λ hijos.

El algoritmo general de una estrategia evolutiva en como sigue:

- 1: Generar de forma aleatoria una población inicial P_λ de λ elementos.
- 2: Para $i = 1$ hasta G (G es el máximo número de iteraciones o generaciones)
 - 3: Evaluar la aptitud de P_λ .
 - 4: Seleccionar de P_λ los mejores μ elementos (P_μ).
 - 5: Mutar y recombinar los elementos de P_μ , hasta crear una nueva población P_λ de λ elementos.
- 6: Reportar a la mejor solución encontrada.

4 Caso de Estudio

Este proyecto se desarrolló en una empresa que produce partes para calentadores de gas. El proyecto se implementó en el área de estampado, la cual cuenta con una línea automatizada de alimentación a prensa para la producción de subensambles de producto final.

Inicialmente se realizó el estudio del área para identificar las variables del proceso y los medios de optimización, al final del estudio se consideraron cuatro variables críticas en el proceso: la velocidad de alimentación a la prensa, la presión de lubricación, el nivel de lubricación y el avance de la lámina. Se tomó como respuesta

de salida, el exceso de material en la pieza, es decir, la función objetivo fue minimizar el exceso de material en la pieza. La variable de salida es importante, porque el exceso de material en las piezas generadas es una fuente de problemas una vez que se ensambla el producto final por lo que es importante mantener este exceso en los límites de tolerancia.

Una vez identificadas las variables principales y la respuesta de salida, se procedió a modelar la relación de las variables de entrada y salida a través de una red neuronal, pues no es posible crear una función analítica que modele este sistema. Una vez construida y entrenada la red neuronal, procede a encontrar los parámetros óptimos a través de una estrategia evolutiva. Una de las ventajas de las estrategias evolutivas, es que no requieren el cálculo del gradiente de la función objetivo a optimizar y trabajan muy bien con variables continuas, que en este caso es una ventaja, pues no es posible calcular la derivada de la función y el problema contiene variables continuas.

Los detalles de la modelación se dan en la sección siguiente.

4.1 Entrenamiento y Validación de la Red Neuronal Artificial

En esta sección se presenta el procedimiento de entrenamiento, validación y resultados del entrenamiento de la red neuronal artificial. Para obtener muestras para entrenar la RNA, se realizaron 35 experimentos, en los cuales se variaron los valores de las variables críticas y se midió la respuesta como el exceso de material promedio de todas las piezas producidas. No se pudieron realizar más experimentos debido a limitaciones en la disponibilidad del equipo, ya que este se encuentra en producción y al costo de los experimentos, pues en cada experimento se gastaba materia prima.

El conjunto de entradas y salidas fue normalizado en un rango de -1 a 1 para facilitar el procedimiento de entrenamiento. El conjunto de entrenamiento fue dividido en tres grupos el 60% de los datos tomó como conjunto de entrenamiento, el 20% se tomó como conjunto de validación durante el entrenamiento y el 20% se tomó como conjunto de prueba de la aproximación final, el entrenamiento usa el algoritmo de Levenberg-Marquardt [15]. La razón para dividir las muestras en los tres grupos antes mencionados, es para evitar que la red neuronal se sobreentrene, es decir, que sea muy efectiva al simular los valores de los datos con los que fue entrenada, pero sea incapaz de reproducir apropiadamente nuevos datos. Para esto se usó el método de detención temprana. Este método consiste en entrenar la RNA exclusivamente con el conjunto de entrenamiento y en cada iteración, medir el error de predicción respecto al conjunto de validación. Conforme la red es entrenada, su error respecto tanto al conjunto de entrenamiento como de validación se reduce, pero llega un momento en que el error respecto al conjunto de validación empieza a incrementarse mientras que el error respecto al conjunto de entrenamiento sigue bajando. Es en este momento cuando se considera que la red se está sobreentrenando y se detiene el entrenamiento. El conjunto de prueba se usa como una verificación final de la capacidad de predicción de la RNA.

Con respecto a la topología usada la red neuronal artificial tienen cuatro entradas siendo las variables críticas independientes y una salida correspondiente al exceso de material en las piezas, así se tiene una capa de salida con una neurona. Se utilizó

como función de transferencia una tangente-sigmoide en la capa oculta y una lineal en la capa de salida.

Para determinar el número de neuronas a usarse en la capa oculta, se corrieron varios experimentos en el entrenamiento de la red usando 3, 4, 5, 6, 7 y 8 neuronas en la capa oculta, para posteriormente calcular el error entre la salida de la red y las salidas de la muestra y elegir el que daba el menor error. El número de neuronas con el mínimo error es cinco, con un error de 0.0032.

Como se mencionó anteriormente, la muestra inicial se divide en tres partes: el conjunto de entrenamiento, con el cual se entrena la RNA; el conjunto de validación, que se usa durante el entrenamiento para evitar que la red se sobreentrene; y el conjunto de prueba, que se utiliza para verificar la generalidad de la red. Una vez que la red es entrenada, se usó un análisis de regresión entre la salida de la red y la salida esperada de la muestra, obteniendo como resultados de la validación que el conjunto de entrenamiento tiene un ajuste de 91%, el de validación de 80 %, el de prueba 81.5% y el de la combinación de los tres conjuntos es de 81.6%. Considerando que un 80% de ajuste es el mínimo necesario para considerar un ajuste es confiable, podemos considerar que la red neuronal aproxima aceptablemente al sistema.

4.2 Optimización a Través de Estrategias Evolutivas

Una vez creado el modelo, se procedió buscar el óptimo de este usando una estrategia evolutiva. Se programó una $EE(\mu; \lambda)$, con $\lambda = 100$ y $\mu = 400$. El algoritmo se corrió por 1000 generaciones. La función objetivo a optimizar fue la RNA ajustada.

Los límites de búsqueda fueron: velocidad de alimentación [10 - 30] pulgadas por minuto; presión de lubricación [15 - 35] psi; nivel de lubricante [1 - 4]; el avance [1.5 - 3.5] pulgadas.

Después de correr la estrategia evolutiva en 10 ocasiones, se tomó el mejor valor generado que consistió en la siguiente combinación de parámetros: velocidad de alimentación = 24 pulgadas por minuto; presión de lubricación = 29 psi; nivel de lubricante = 1; avance = 1.5 pulgadas.

5 Conclusiones

Después de aplicar técnicas de inteligencia artificial, se pudo identificar un conjunto de parámetros optimizados, que minimizan el exceso de material en las piezas producidas. Esto ha permitido reducir el re-trabajo de piezas defectuosas, aumentando la productividad. Los parámetros obtenidos ya se usan en planta, y han facilitado en gran medida la operación de la alimentación de la prensa. Pues se evita la necesidad de ajustar por ensayo y error los parámetros de la máquina.

Las redes neuronales resultaron una herramienta muy versátil para su uso en este trabajo. Igualmente, las estrategias evolutivas fueron implementadas usando código libre de internet, por lo que su uso también fue extremadamente sencillo y rápido.

Podemos concluir que las herramientas de inteligencia artificial pueden implementarse de forma rápida y efectiva para resolver problemas industriales en un tiempo corto y con poca inversión, lo que representa una gran ventaja competitiva.

Como trabajo futuro, se planea explorar otras arquitecturas de redes neuronales, como por ejemplo redes neuronales con funciones de base radial[16]. Esto con el fin de encontrar un mejor ajuste de los datos.

6 Agradecimientos:

Agradecemos de forma especial al CONACYT por su apoyo para la realización de este proyecto a través del Programa de Estímulos a la Innovación 2010, en la modalidad INNOVAPYME.

7 Referencias

1. Serope Kalpakjian y Steven R. Schmid. *Manufactura, ingeniería y tecnología*. Pearson education. Cuarta Edición (2002). 393-402.
2. Fandón, S, Hoyos, C, Fernández, D. Diseño de troqueles de estampación mediante modelado sólido. Recuperado el 2 de febrero de 2009
3. A.Y.C. Nee and V.C. Venkatesha. A Heuristic Algorithm for Optimum Layout of Metal Stamping Blanks (2008)
4. A. Yanagida and A. Azushima. Evaluation of coefficients of friction in hot stamping by hot flat drawing test. (2009).
5. Hurtado Jorge y Álvarez Diego. Optimización basada en confiabilidad por medio de redes neuronales y algoritmos evolutivos, *Revista internacional de métodos numéricos para cálculo y Diseño en ingeniería* (2002).
6. Marek Balizinki, Ernest Czogala, Krzysztof Jemielniak, Jacek Leski. Tool condition monitoring using artificial intelligence methods. *Engineering Applications of Artificial Intelligence* (2002).
7. McCulloch, W. and Pitts, W. A logical calculus of the ideas immanent in nervous activity. In *Bulletin of Mathematical Biophysics*. 5: 115-133. (1943).
8. Rosenblatt, F. The perceptron: A probabilistic model for information storage and organization in the brain. In *Psychological Review*. 65: 386-408. (1958).
9. Widrow, B. and Hoff, M.E. Adaptive switching circuits. In *1960 IRE WESCON Convention Record*. IRE Part 4: 96-104. (1960).
10. Minsky, M. and Papert, S. *Perceptrons*. MIT Press. Cambridge, MA. (1969).
11. Hornik, K.M., Stinchcombe, M. and White, H. Multilayer feedforward networks are universal approximators. *Neural Networks*, 2: 359-366. (1989).
12. Werbos, P.J. Beyond regression: New tools for prediction and analysis in the behavioral sciences. *PHD Thesis*, Harvard University, Cambridge, MA. (1974).

13. Hans-Paul Schewefel, *Evolution and Optimum Seeking: The Sixth Generation*, 1993, John Wiley & Sons, Inc., New York, Usa.
14. David E. Goldberg, *Genetic Algorithms in Search, Optimization, and Machine learning*, 1989, Addison Wesley, Boston MA.
15. Hagan, M.T., Demuth, H.B. and Beale, M. *Neural Network Design*. PWS Publishing Co., Boston, Ma. (1997).
16. D.S. Broomhead and D. Lowe, *Multivariable functional interpolation and adaptive networks*. *Complex Syst.* (1988).

7.3. Anexo III

Publicación en el Congreso Internacional de Ingeniería Industrial.

Proceedings of the 15th Annual
International Conference on Industrial Engineering
Theory, Applications and Practice
Mexico City, Mexico
October 17-20, 2010

USING ARTIFICIAL NEURAL NETWORKS TO APPROXIMATE LOSS COEFFICIENT FUNCTIONS IN PRELIMINARY TURBINE DESIGN

Susana Viridiana Gutiérrez and Giovanni Lizarraga

Gerencia de Desarrollo Humano
Corporación Mexicana de Investigación en Materiales S.A. de C.V.
Ciencia y Tecnología 790
Saltillo 400
Saltillo, Coahuila 25290
Corresponding author's e-mail: glizarraga@comimsa.com

Abstract: One of the initial steps when designing a turbine is the preliminary mean line design. The mean line design is important because it is the starting point where more advanced steps start. An important aspect in the mean line design is the estimation of the losses due to friction in the different components of a turbine. Several charts, that relate the losses in energy with the other aspects of the turbine, have been published. Unfortunately, we cannot include these charts in a computer program in order to automate the design procedure. In this work, we use artificial neural networks to approximate these charts. It is common to iteratively recalculate the efficiency of a turbine based, on the results of these charts. When the charts are stored in a neural network, these iterative procedures can be done in automatically by a computer, resulting in faster and more accurate designs.

1. INTRODUCTION

Gas turbines are devices that extract energy from a fluid and transform this energy into useful work. As the name suggest, gas turbines use gas as the working fluid. Other kinds of turbines use other fluids to generate work. Turbines work with a continuously flowing fluid that interacts with rotating blades in order to generate work. Gas turbines are classified in axial turbines and radial turbines. In axial turbines, the fluid flows mainly in an axial direction through the length of the turbine. In radial turbines, the fluid enters to the turbine in a plane perpendicular to the turbine axis. Then the fluid is turned and leaves the turbine following the axial direction. In this work we focus on axial turbines for power generation.

Two of the most important components of a turbine are the rotor and the stator. The stator is a fixed ring of blades or airfoils, that receives the fluid with angle α_1 . Then, the stator accelerates the flow so it arrives to the rotor with angle α_2 . The rotor is a circular array of blades, that turns as the fluid passes through it. The movement of the rotor turns a shaft, and this shaft transmit power that is transformed into movement or electricity. The fluid enters to the rotor with angle α_2 , and leaves the rotor with an angle α_3 . The change in the flow of the fluid ($\alpha_3 - \alpha_2$) is very important, because it is related with quantity of work that is performed by the rotor.

The combination of a rotor with its corresponding stator is called a stage. In order to extract as much energy as possible from a fluid, several stages may be necessary. One of the most important parameters to consider in the design is the losses due to friction. These losses have a direct impact in the efficiency of the machine. In the long term, small differences in efficiency may represent great differences in gas consumption.

Several methods to estimate the losses in the energy of the fluid been developed. These methods use some charts that relate the incidence angles of the fluid and other non-dimensional parameters with the efficiency of the stage. A well known example is the Smith chart (Smith, 1965).

Calculating losses in a turbine is very important in order to optimize the design. In order to calculate these losses, several charts have been created. These charts relate some geometric properties of the turbine with the reduction of energy in the fluid. If we want to optimize the design of turbine using, for example, optimization algorithms, it is necessary to represent these charts as a function that can be implemented in a computer. The goal of this work is to approximate several charts frequently used in bibliography, with neural networks, so they can be used in a computer. The rest of the article is organized as follows: in Section 2, we introduce some basic concepts of loss coefficients in turbine design. In Section 3 we give an introduction Artificial Neural Networks. In Section 4, we describe the procedure to approximate functions using neural networks; and the results of the approximations. Finally, in Section 5 we state our conclusions.

Proceedings of the 15th Annual
International Conference on Industrial Engineering
Theory, Applications and Practice
Mexico City, Mexico
October 17-20, 2010

2. LOSS COEFFICIENTS IN TURBINE DESIGN

The concepts presented in this section are based on the following bibliography Cohen (1996), Turton (1995) and Moustapha (2003). Designing a turbine encloses several iterative steps. The first step is the mean line design, where all calculations are realized assuming that the conditions at the mean radius of the turbine is representative of the conditions of the whole cross section. In this step, the angles that the fluid follows through the stages are calculated. Other geometrical conditions, as the tip and hub radius, are determined also.

During the mean line design is important to estimate the losses in the turbine, even when the general geometry is not determined yet. In order to make such estimations, several models for losses in turbines have been developed. One of the most popular is that of Ainley and Mathieson (1951). This method has revised several times. We based this work in the modification described in Moustapha (2003).

In this model, there are several important charts that need to be consulted in order to determine the losses. These charts relate the pitch/chord ratio of the rotor and the exit angle α_3 of the rotor with the losses in the rotor. These charts can be found in Moustapha (2003), in page 36. In that page the chart (a) will be known from now on as Chart 1, chart (b) will be known from now on as Chart 2 and chart (d) will be known from now on as Chart 3. In the following sections we will explain how to approximate these charts using Artificial Neural Networks.

3. ARTIFICIAL NEURAL NETWORKS

3.2 General concepts

The study of artificial neural networks is part of artificial intelligence. Artificial Neural Networks (ANN) are systems inspired in the human brain, that can approximate function or classify patterns. The studies in ANN started with the work of McCulloch and Pitts (1943) and was continued by many others, for example Rosenblatt (1958), Widrow and Hoff (1960), Minsky and Papert (1969), and many others.

An example of an ANN can be seen in Figure 1, where we can see some of the elements of an ANN.

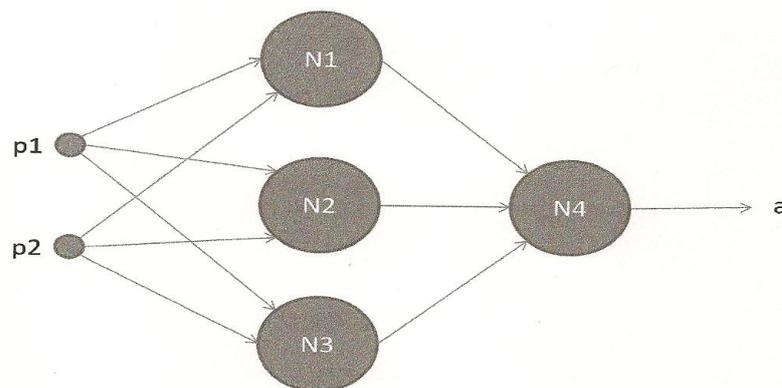


Figure 1. An example of an Artificial Neural Network.

In this example we have two input values, represented by $p1$ and $p2$, but an ANN can have any finite number of inputs. The neurons in this NET are represented by the circles $N1$, $N2$, $N3$ and $N4$. The neurons $N1$, $N2$, $N3$ form the first layer or the NET. The first layer receives and processes the inputs of the network, and transmits an output to the second layer. The

Proceedings of the 15th Annual
International Conference on Industrial Engineering
Theory, Applications and Practice
Mexico City, Mexico
October 17-20, 2010

second layer in this example consists of N_4 . In this example, the second layer receives the outputs of the first layer and returns the output of the network (a). This network represents a function that receives two values (p_1 and p_2) and returns a value (a). ANNs can have several layers. The final layer, that returns the response of the network to the inputs, is known as the output layer. The layers between the output layer and the inputs are called hidden layers. Hidden layers do most of the work when approximating a function. Each layer of an ANN, including the output layer, can have an arbitrary number of neurons. Each neuron from one layer transmits a signal to each neuron of the next layer. This topology is inspired in the way that neurons are interconnected in the brain.

The general topology of a single neuron in an ANN is shown in Figure 2.

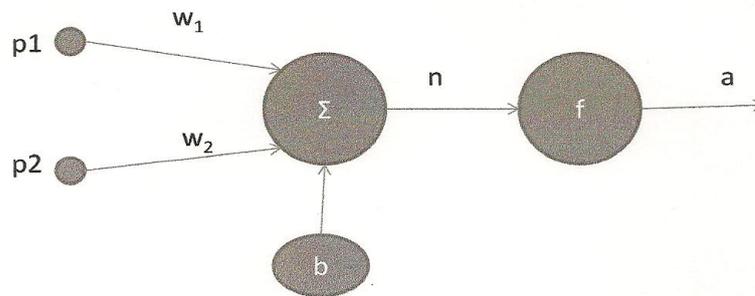


Figure 2. A single neuron.

In this figure, we see that a neuron receives two inputs p_1 and p_2 . The inputs may be the values of the net input, or the outputs of previous layers. Each input is multiplied by a weight w_{ij} , where i is the number of the neuron that receives the input, and j is the number of the input. These multiplications are added up together with another weight b , known as the bias. The result of this addition is called d . Next, d is modified by a function f , known as the transfer function. Finally, the evaluation of the transfer function is the output “ a ” of the neuron.

In a neural network, each neuron is located in a layer and has a number in that layer. A practical nomenclature to locate elements of a neural network is to use the following indexation: e_i^k , where “ e ” represents an element of a network, k , indicates the layer of the element and i indicates the neuron of “ e ”. For example, b_2^1 is the bias of the second neuron in the first layer; a_3^4 stands for the output of the third neuron in the fourth layer. A slightly different nomenclature is used to name the weights in a network. We use w_{ij}^k to name the weight of the i -th neuron in layer k that is multiplied by the j -th input.

The transfer function f is usually the same for neuron in the same layer, but it can be different for different layers. Some of the most common transfer functions are listed in Table 1.

Table 1. Transfer functions.

FUNCTION	DEFINITION
Hard Limits	$f(n) = 0$ for $n < 0$ $f(n) = 1$ for $n > 0$ or $n = 0$
Linear	$f(n) = n$
Log-Sigmoid	$f(n) = (1 + e^{-n})^{-1}$
Hyperbolic Tangent Sigmoid	$f(n) = (e^n - e^{-n}) / (e^n + e^{-n})$
Positive Linear	$f(n) = 0$ for $n < 0$ $f(n) = n$ for $n > 0$ or $n = 0$

It is demonstrated that an ANN with two layers of neurons can approximate any function to any degree, as long as we have enough neurons in the hidden layer (Hornik et al., 1989). For this end, the hidden layer must have a sigmoid transfer

Proceedings of the 15th Annual
International Conference on Industrial Engineering
Theory, Applications and Practice
Mexico City, Mexico
October 17-20, 2010

function, and the output layer must use a linear transfer function. But it is necessary to estimate the number of neurons in the hidden layer. Charts 1, 2 and 3 can be seen as functions, so we can approximate them using Artificial Neural Networks.

3.2 Training an Artificial Neural Network

The predicting power of an ANN is based on the adjustment of its weights and biases. This led us to the question of how to calculate the right values for weights and biases, so the ANN can approximate a function. A great advantage of ANNs is that they are able "to learn" the right values for they weights and biases through a learning rule. A learning rule is a procedure to calibrate the parameters of the net, until it reaches a desirable approximation.

For multilayer networks, the training procedure is the back propagation algorithm (Werbos, 1974). This algorithm is based in the steepest descent algorithm for optimization (Hagan et al. 1997). In order to train the net, we need a set of examples. We need a set $\{p_1, p_2, \dots, p_n\}$ of input values (where each p_i may be a vector), and the corresponding set $\{t_1, t_2, \dots, t_n\}$ of desired output values. The training is designed to minimize the mean error between the outputs of the net and the expected outputs t_i . Matlab 7 contains the implementations of several efficient algorithms to train an Artificial Neural Network.

4. EXPERIMENTS

4.1 Training procedure

In this section we present the procedure followed to train the Artificial Neural Networks and the results of the training. In order to approximate Charts 1, 2 and 3, we take 131 samples from Chart 1, 156 samples from Chart 2 and 393 samples from Chart 3. The samples are composed by the inputs and their corresponding outputs.

All samples, both inputs and outputs, were normalized in the range of -1 and 1 in order to facilitate the training procedure. The training sets were divided as follows: we took 60% of the samples as the training set, 20% of the samples as the validation set during the training and 20% of the samples to test the final approximation. To train the neural network, we used the algorithm of Levenberg-Marquardt. See Hagan (1997) for details.

With respect to the topology, all ANNs have two inputs, because all charts have two independent variables. Also, all the ANNs have one output. So, the output layer consists in a single neuron. We use a two layer network, with sigmoid transfer functions in the hidden layer, and linear transfer function in the output layer.

4.2 Neurons in hidden layer

In order to determine how many neurons we use in the hidden layer, we run the following experiments. We trained a neural network using 3, 4, 5, 6, 7, 8, 9 and 10 neurons in the hidden layer. Next, for each number of neurons in the hidden layer, we trained the net ten times and calculated the error between the outputs of the net and the expected outputs. Finally, we calculated the mean error for each number of neurons in the hidden layer. These experiments are used for each one of the charts.

The results of the experiments are the following:

- a) For Chart 1, the number of neuron with the minimum error is 3, with an error of 0.00003527.
- b) For Chart 2, the number of neuron with the minimum error is 4, with an error of 0.000007692.
- c) For Chart 2, the number of neuron with the minimum error is 4, with an error of 0.000007692.

The conclusions from these experiments are straightforward. Chart 1 must be approximated using a neural network with 3 neurons in the hidden layer, Chart 2 must be approximated using 4 neurons in the hidden layer, and Chart 3 must be approximated using 4 neurons in the hidden layer.

Proceedings of the 15th Annual
International Conference on Industrial Engineering
Theory, Applications and Practice
Mexico City, Mexico
October 17-20, 2010

4.3 Validating the results

As mentioned before, the samples are divided in three parts: the training set, the validation set and the test set. The training set is used to calibrate the weight and biases of the neural network to obtain the desired outputs. The validation set is used to prevent a problem known as overtraining. This problem occurs when the trained ANN approximates very well the outputs of the training set, but fails to approximate other samples. The test set is used as a final validation of the trained network.

Once the ANNs are trained, we use a regression analysis between the outputs of the network and the expected outputs. We performed this analysis using:

1. The training set.
2. The validation set.
3. The test set.
4. All three sets combined.

The results of these validations are shown in Table 2.

Table 2. Correlation coefficient between the output of the ANNs and the expected outputs.

	Chart 1	Chart 2	Chart 3
Training Set	0.9722	0.9960	0.9928
Validation Set	0.9664	0.9906	0.9759
Test Set	0.9750	0.9948	0.9978
All Sets Combined	0.9705	0.9946	0.9898

As we can see in the table, the correlation coefficients are above 0.96 in all cases and, in many cases, above 0.99. This indicates a close correlation between the outputs of the ANNs and the charts.

4.4 Final weights of the network

For the ANN that approximates Chart 1, the final weights and biases are the following: $w_{11} = 0.9545$, $w_{12} = 2.3558$, $w_{21} = -1.6651$, $w_{22} = 0.3680$, $w_{31} = 1.4762$, $w_{32} = -2.9602$, $b_1 = -1.3461$, $b_2 = -1.2494$, $b_3 = 2.9793$. For the ANN that approximates Chart 2, the final weights and biases are the following: $w_{11} = -1.7716$, $w_{12} = 15.9176$, $w_{21} = 5.6554$, $w_{22} = 7.5006$, $w_{31} = 0.6220$, $w_{32} = 1.0377$, $w_{41} = 0.5029$, $w_{42} = 0.5029$, $b_1 = -5.9472$, $b_2 = -7.2306$, $b_3 = -1.3836$, $b_4 = 1.6072$. For the ANN that approximates Chart 3, the final weights and biases are the following: $w_{11} = -0.8686$, $w_{12} = -4.1233$, $w_{21} = 1.5789$, $w_{22} = -1.2886$, $w_{31} = 0.8087$, $w_{32} = 1.7320$, $w_{41} = 0.4424$, $w_{42} = -2.1351$, $b_1 = 3.5586$, $b_2 = -1.0415$, $b_3 = 0.2198$, $b_4 = 1.1066$.

With this information, it is easy to implement this Artificial Neural Networks in a computer program, so in an automated way we can optimize and turbine designs.

5. CONCLUSIONS AND FUTURE WORK

In this work, we approximated some charts to calculate the loss coefficient in gas turbines. We used a standard procedure and founded good approximations that were validated using a regression analysis. This is an example of how neural networks can be easily used and trained to approximate charts commonly used in engineering. The next step is to use these neural networks to optimize designs. A useful tool for this is evolutionary algorithms (Goldberg, 1989). Evolutionary algorithms can work with any kind of functions in order to search for the optimal solution of a problem.

Proceedings of the 15th Annual
International Conference on Industrial Engineering
Theory, Applications and Practice
Mexico City, Mexico
October 17-20, 2010

6. REFERENCES

- Ainley, D.G. and Mathieson G.C.R. (1951). A method of performance estimation of axial flow turbines. Aero. Res. Council Reports and Memoranda 2974.
- Cohen, H., Rogers, G., and Saravanamuttoo, H. (1996). *Gas Turbine Theory*. Longman Group Limited, Essex England.
- Goldberg, D. (1997). *Genetic Algorithms in Search, Optimization, and Machine Learning*. ADDISON WESLEY, Boston, Ma.
- Hagan, M.T., Demuth, H.B., and Beale, M. (1997). *Neural Network Design*. PWS Publishing Co., Boston, Ma.
- Hornik, K.M., Stinchcombe, M., and White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, 2: 359-366.
- McCulloch, W. and Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. In *Bulletin of Mathematical Biophysics*. 5: 115-133.
- Minsky, M. and Papert, S. (1969). *Perceptrons*. MIT Press. Cambridge, MA.
- Moustapha, H., Zelesky, M. F. , Baines, N. C. and Japikse, D. (2003). *Axial and Radial Turbines*. Concepts NREC, White River Junction, USA.
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. In *Psychological Review*. 65: 386-408.
- Smith, S.F. (1965). A simple correlation of turbine efficiency. *Journ Royal Aero Soc.* 69: 467-470.
- Turton, R. (1995). *Principles of turbomachinery*. Chapman & Hall, London.
- Werbos, P.J. (1974). Beyond regression: New tools for prediction and analysis in the behavioral sciences. *PHD Thesis*, Harvard University, Cambridge, MA.
- Widrow, B. and Hoff, M.E. (1960). Adaptive switching circuits. In *1960 IRE WESCON Convention Record*. IRE Part 4: 96-104.